


UNIVERSIDADE FEDERAL DO PARANÁ

NAÍSSA BATISTA DA LUZ

INTEGRAÇÃO DE ANÁLISE ORIENTADA A OBJETOS E ÁRVORES DE DECISÃO  
PARA CLASSIFICAÇÃO DE SUB-TIPOLOGIAS DE FLORESTA OMBRÓFILA  
MISTA

CURITIBA

2011



NAÍSSA BATISTA DA LUZ

INTEGRAÇÃO DE ANÁLISE ORIENTADA A OBJETOS E ÁRVORES DE  
DECISÃO PARA CLASSIFICAÇÃO DE SUB-TIPOLOGIAS DE FLORESTA  
OMBRÓFILA MISTA

Tese apresentada ao Curso de Pós-Graduação em Ciências Geodésicas, Departamento de Ciências Geodésicas, Setor de Ciências Exatas e da Terra, Universidade Federal do Paraná, como requisito parcial à obtenção do título de Doutor em Ciências Geodésicas.

Orientador: Prof Dr. Alzir Felipe Buffara Antunes

Co-orientador: Prof Dr. Hideo Araki

CURITIBA

2011

Catálogo na Fonte: Sistema de Bibliotecas, UFPR  
Biblioteca de Ciência e Tecnologia

---

- L979i Luz, Naíssa Batista da  
Integração de análise orientada a objetos e árvores de decisão para  
classificação de sub-tipologias de floresta ombrófila mista / Naíssa Batista da  
Luz. – Curitiba, 2011.  
156 f.: il., tab., grafs., maps.
- Tese (doutorado) – Universidade Federal do Paraná, Setor de Ciências  
Exatas e da Terra, Programa de Pós-Graduação em Ciências Geodésicas, 2011.
- Orientador: Alzir Felipe Buffara Antunes  
Coorientador: Hideo Araki.  
Bibliografia: p. 119-133
1. Algoritmos – Árvores de decisão. 2. Imagens de sensoriamento remoto.  
3. Florestas tropicais. I. Antunes, Alzir Felipe Buffara. II. Araki, Hideo. III.  
Título.

CDD: 526.982

---

Bibliotecária: Roseny Rivelini Morciani CRB-9/1585

## TERMO DE APROVAÇÃO

NAÍSSA BATISTA DA LUZ

"INTEGRAÇÃO DE ANÁLISE DE IMAGENS ORIENTADA A OBJETOS E  
ÁRVORES DE DECISÃO PARA CLASSIFICAÇÃO DE SUB-TIPOLOGIAS DE  
FLORESTA OMBRÓFILA MISTA"

Tese nº 75 aprovada como requisito parcial do grau de Doutor no Curso de Pós-Graduação em Ciências Geodésicas, Setor de Ciências da Terra da Universidade Federal do Paraná, pela seguinte banca examinadora:

Orientador:



Prof. Dr. Alzir Felipe Buffara Antunes  
Departamento de Geomática, UFPR



Profª. Drª. Maria de Lourdes Bueno Trindade Galo  
Universidade Estadual Paulista, UNESP



Drª. Maria Augusta Doetzer Rosot  
Empresa Brasileira de Pesquisa Agropecuária - EMBRAPA



Profª. Drª. Christel Lingnau  
Departamento de Ciências Florestais, UFPR



Prof. Dr. Jorge Antonio Silva Centeno  
Departamento de Geomática, UFPR

Curitiba, 01 de julho de 2011.



Aos meus pais,  
Jaime Schmitt da Luz e Maria Ângela Batista da Luz,  
pela proteção e apoio incondicionais,  
dedico este trabalho.  
Muito obrigada por tudo!

## **AGRADECIMENTOS**

Ao Conselho Nacional de Desenvolvimento Científico e Tecnológico, CNPq, pelo apoio financeiro através da bolsa de estudos e da taxa de bancada, sem o qual a realização deste trabalho seria impossível.

À Coordenação de Aperfeiçoamento de Pessoal de Nível Superior, CAPES, pela possibilidade de enriquecer este trabalho através da permanência na University of Hawai'i, viabilizada pela bolsa de Doutorado Sanduíche.

À Universidade Federal do Paraná, onde busco conhecimento desde 1994, quando ingressei na graduação em Engenharia Florestal. Especialmente ao Curso de Pós-graduação em Ciências Geodésicas, por ter me acolhido durante o curso de Doutorado e pela oportunidade de compartilhar da sabedoria de seus mestres. Ao laboratório de Sensoriamento Remoto e ao seu coordenador, Professor Dr. Jorge da Silva Centeno, pela utilização das dependências e equipamentos.

À University of Hawai'i, ao Remote Sensing Laboratory e ao Professor PhD Qi Chen, por ter me recebido, cedido o laboratório e pelas valiosas discussões técnicas.

Ao meu orientador, Professor Dr. Alzir Felipe Buffara Antunes, que com amizade e carinho me guiou nesta jornada.

Ao meu co-orientador, Professor Dr. Hideo Araki, pelas discussões técnicas e auxílio no desenvolvimento deste trabalho.

Ao colega Dalmar José dos Santos, pela cessão dos aplicativos e pelo “auxílio à comunidade”.

Aos colegas de disciplinas, com quem dividi a “salinha de estudos”, Diuliana Leandro, Renan Martins Pombo, Suelen Cristina Movio Huinca e Alessandro Salles Carvalho, pelo suporte em um momento difícil e pela amizade.

Aos colegas do laboratório, Graziella Valença de Souza, Fabiana Silva e Andrey Augusto Alves de Oliveira.

À minha amiga Caroline Bergamo Gonçalves, colega de curso, companheira de estudos e amiga de todas as horas.

Aos meus amigos, pelo suporte e pelo brilho que trazem à minha vida.

Aos meus irmãos queridos, Ramiro e Enrico, suas companheiras, Nerli e Karine, e meu amado sobrinho, Miguel.

Aos meus amados avós, Oswaldo Baptista e Dirce Baptista (*in memoriam*), pelos exemplos de vida e bondade que representam.

Aos meus pais, meu suporte, pelo apoio e amor incondicionais.

*“What we are doing to the forests of the world is but a mirror reflection of what we are doing to ourselves and to one another.”*

Mahatma Gandhi



## RESUMO

Tem-se observado desde o começo do século XX uma dramática redução da área de ocorrência original da Floresta Ombrófila Mista. Atualmente, os fragmentos deste tipo florestal estão estimados em 2 a 4% da área de cobertura original e as florestas em estágios primários, ou mesmo avançados, não perfazem mais de 0,7% da área original. A Reserva Florestal Embrapa/Epagri (RFEE), no Município de Caçador (SC) é considerada um dos últimos grandes remanescentes de Floresta Ombrófila Mista. Técnicas voltadas ao mapeamento e ao monitoramento deste ecossistema se fazem necessárias para que ações de planejamento da conservação e do manejo sustentável deste ecossistema possam ser adotadas. Este trabalho visa propor uma metodologia para extração de informações a partir de dados do satélite Ikonos-II que permita o incremento da qualidade da classificação digital de padrões visando subsidiar o monitoramento da Floresta Ombrófila Mista. Para tanto, foram adotadas técnicas promissoras e inovadoras de processamento digital de imagens, como a segmentação multi-resolução e algoritmos de classificação por árvores de decisão. Adicionalmente, foi aplicada a metodologia que permite a avaliação quantitativa dos resultados da segmentação, visando à seleção dos parâmetros de segmentação que permitem o delineamento automático dos objetos da imagem que mais se aproximam ao mapa-referência. Atributos espectrais, da textura e da forma dos polígonos da segmentação foram calculados, totalizando 405 imagens auxiliares à classificação. Os métodos de seleção por meio da indução de árvores de decisão e da aplicação do teste estatístico T de Student permitiram a redução da dimensionalidade dos dados de entrada de 6 a 18%. Foram utilizados os algoritmos de classificação por árvores de decisão *RandomTree*, *RepTree*, *SimpleCART*, *CART* e *J48*. Os resultados obtidos indicam que a metodologia proposta tem potencial na discriminação de tipologias da Floresta Ombrófila Mista. Houve um incremento da qualidade do mapa de uso e cobertura da terra da RFEE de aproximadamente 30%, quando comparado a resultados obtidos anteriormente e avaliados pelo mesmo mapa de referência. Um valor de exatidão igual a 83,36% foi obtido com o algoritmo de árvore de decisão *SimpleCART*, quando a imagem gerada pelos parâmetros de segmentação selecionados utilizando a metodologia de avaliação quantitativa foi aplicada.

Palavras-chave: imagens Ikonos-II; algoritmos de árvore de decisão; segmentação multi-resolução; classificação baseada em objetos; Floresta Ombrófila Mista.

## ABSTRACT

A dramatic area reduction on original Mixed Ombrophyllus Forest occurrence has been observed since early 20<sup>th</sup> Century. Nowadays this ecosystem forest remnants occupy 2 to 4% of its original cover area and primary or even advanced forests represent less than 0,7%. The Embrapa/Epagri Forest Reserve, located at Caçador County, Santa Catarina State, encompasses one of the most important and last forest remnants representing this ecosystem. In order to actions such as conservation planning and sustainable forest management to take place, techniques aiming this particular type of forest mapping and monitoring are needed. The present work intends to provide Ikonos-II data information extraction methodology, allowing higher quality forest pattern classification as means to subsidize Mixed Ombrophyllus Forest monitoring. As so, advanced and promising techniques such as multi-resolution segmentation and decision tree classification algorithms were adopted. Additionally, a quantitative segmentation evaluation methodology was adopted allowing segmentation parameters selection in a way that image objects resemble the visually defined reference map. Spectral, textural and shape attributes were calculated for segmentation polygons, allowing generation of 405 auxiliary image for classification. Using attribute selection methods such as decision tree induction and Student's T-test indulged dataset dimensionality reduction to 6 to 18%. Decision tree algorithms *RandomTree*, *RepTree*, *SimpleCART*, *CART* and *J48* were used. The results obtained indicate that the proposed methodology presents great potential for Mixed Ombrophyllus Forest discrimination. Compared to previous results, a 30% increase on Land Cover Land Use Map quality was accomplished. *SimpleCART* decision tree algorithm applied to 155 scale parameter and 0,1 shape factor image segmentation generated the highest overall accuracy, equals to 83,36%.

Keywords: Ikonos-II imagery; decision tree algorithms; multi-resolution segmentation; object-based classification; Mixed Ombrophyllus Forest.

## LISTA DE FIGURAS

FIGURA 1. UMA ÁRVORE DE DECISÃO QUE DESCREVE A OBSERVAÇÃO DO VÔO DE UM PÁSSARO, COM CADA UMA DAS FOLHAS DESCREVENDO OS VALORES BINÁRIOS DE VÔO.....	51
FIGURA 2. LOCALIZAÇÃO DA RESERVA FLORESTAL EMBRAPA/EPAGRI, MUNICÍPIO DE CAÇADOR, ESTADO DE SANTA CATARINA.....	61
FIGURA 3. FLUXOGRAMA DAS ATIVIDADES QUE COMPÕEM A METODOLOGIA ADOTADA PARA A EXTRAÇÃO DE INFORMAÇÕES A PARTIR DAS IMAGENS IKONOS-II. ....	70
FIGURA 4. FLUXOGRAMA DAS ATIVIDADES QUE COMPÕEM A METODOLOGIA ADOTADA PARA A EXTRAÇÃO DE INFORMAÇÕES A PARTIR DAS IMAGENS IKONOS-II. ....	72
FIGURA 5. REPRESENTAÇÃO DA DIVISÃO DO ESPAÇO DE COMBINAÇÕES ENTRE O PARÂMETRO DE ESCALA E O FATOR DE FORMA E OS PARES DE PARÂMETROS AVALIADOS NAS FASE I; II; III E IV (EM (A); (B); (C) E (D), RESPECTIVAMENTE).....	77
FIGURA 6. DISTÂNCIA ENTRE OS CENTROS DE MASSA: (A) DISTÂNCIA EUCLIDIANA ENTRE OS CENTROS; (B) MENOR DISTÂNCIA ENTRE OS CENTROS DE MASSA).....	80
FIGURA 7. DETERMINAÇÃO DA FAIXA DE COINCIDÊNCIA.....	81
FIGURA 8. AMOSTRAS DE VERIFICAÇÃO SOBREPOSTAS À IMAGEM EM COMPOSIÇÃO COLORIDA, COM AS BANDAS DAS REGIÕES DO VERMELHO, VERDE E AZUL NOS CANAIS RGB. ....	91
FIGURA 9. COMPARAÇÃO ENTRE RECORTE DA IMAGEM REFERÊNCIA, SOBREPOSTA À COMPOSIÇÃO DA IMAGEM IKONOS-II COM AS BANDAS DO VERMELHO, VERDE E AZUL NOS CANAIS RGB, EM (A); E AS IMAGENS SEGMENTADAS COM PE-300 (B), PE-325(C) E PE-350 (D). ....	93
FIGURA 10. SEGMENTAÇÃO OBTIDA COM A APLICAÇÃO DO PARÂMETRO DE ESCALA DE 550 E O FATOR DE FORMA IGUAL A 0,1 (A) E SEGMENTAÇÃO OBTIDA COM A APLICAÇÃO DO PE-550 E DO FF-0,9 (B). ....	95
FIGURA 11. SUPERFÍCIE GERADA PELA INTERPOLAÇÃO ESPACIAL DO ÍNDICE DE AVALIAÇÃO DA SEGMENTAÇÃO, CALCULADO DURANTE A FASE I, EM FUNÇÃO DO PARÂMETRO DE ESCALA E DO FATOR DE FORMA. ....	96
FIGURA 12. COMPARAÇÃO DO RESULTADO DE SEGMENTAÇÃO COM O PE-150 SELECIONADO NA FASE I (B), COM OS ELEMENTOS VIZINHOS NO ESPAÇO DE BUSCA DA SOLUÇÃO ÓTIMA, PE-50 (A) E PE-250 (C). FF CONSTANTE IGUAL A 0,1.....	97

FIGURA 13. SUPERFÍCIE GERADA PELA PLOTAGEM DO ÍNDICE DE AVALIAÇÃO DA SEGMENTAÇÃO, CALCULADO DURANTE A FASE II, EM FUNÇÃO DO PARÂMETRO DE ESCALA E DO FATOR DE FORMA. ....	98
FIGURA 14. COMPARAÇÃO DO RESULTADO DE SEGMENTAÇÃO COM O PE-150 SELECIONADO NA FASE II (B), COM OS ELEMENTOS VIZINHOS NO ESPAÇO DE BUSCA DA SOLUÇÃO ÓTIMA, PE-125 (A) E PE-175 (C). FF CONSTANTE IGUAL A 0,1. ....	99
FIGURA 15. SUPERFÍCIE GERADA PELA PLOTAGEM DO ÍNDICE DE AVALIAÇÃO DA SEGMENTAÇÃO, CALCULADO DURANTE A FASE III, EM FUNÇÃO DO PARÂMETRO DE ESCALA E DO FATOR DE FORMA. ....	100
FIGURA 16. COMPARAÇÃO DOS RESULTADOS DE SEGMENTAÇÃO COM A REDUÇÃO E AUMENTO DO PARÂMETRO DE ESCALA DE 155 (B), SELECIONADO NA FASE III, PARA 150 (A) E 160 (C). FATOR DE FORMA CONSTANTE IGUAL A 0,1. ....	100
FIGURA 17. SUPERFÍCIE GERADA PELA PLOTAGEM DO ÍNDICE DE AVALIAÇÃO DA SEGMENTAÇÃO, CALCULADO DURANTE A FASE IV, EM FUNÇÃO DO PARÂMETRO DE ESCALA E DO FATOR DE FORMA. ....	101
FIGURA 18. EXEMPLO DO FORMATO DE ÁRVORE DE DECISÃO GERADO PELO SOFTWARE WEKA (A) E DO FORMATO IF-ELSE IMPLEMENTADO NO SOFTWARE MATLAB (B). ....	106
FIGURA 19. EXEMPLO GRÁFICO DE ÁRVORE DE DECISÃO GERADA PELO SOFTWARE WEKA. ....	106
FIGURA 20. MAPAS DE USO E COBERTURA DA TERRA DA RFEE, OBTIDOS POR INTERPRETAÇÃO VISUAL (A) E CLASSIFICAÇÃO DA IMAGEM IKONOS-II (B). SISTEMA DE PROJEÇÃO: UNIVERSAL TRANSVERSE MERCATOR. DATUM: SAD-69. ....	115



## LISTA DE TABELAS

TABELA 1. DADOS DE OBSERVAÇÕES DE ATRIBUTOS RELACIONADOS AO PROBLEMA DE APRENDIZADO DO VÔO DE PÁSSAROS.....	49
TABELA 2. CARACTERÍSTICAS DAS IMAGENS IKONOS-II. ....	66
TABELA 3. CONJUNTOS DE DADOS DE ENTRADA COMPOSTOS PELAS BANDAS DAS IMAGEM IKONOS-II E ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO UTILIZADOS PARA A CLASSIFICAÇÃO DAS IMAGENS.....	103
TABELA 4. RESULTADOS DA AVALIAÇÃO DA EXATIDÃO DO MAPEAMENTO DO USO E COBERTURA DA TERRA NA ÁREA DA RFEE, GERADO POR MEIO DA CLASSIFICAÇÃO DOS ATRIBUTOS DOS POLÍGONOS OBTIDOS COM A APLICAÇÃO DO PE-325 E FF-0,1. ....	107
TABELA 5. RESULTADOS DA AVALIAÇÃO DA EXATIDÃO DO MAPEAMENTO DO USO E COBERTURA DA TERRA NA ÁREA DA RFEE, GERADO POR MEIO DA CLASSIFICAÇÃO DOS ATRIBUTOS DOS POLÍGONOS OBTIDOS COM A APLICAÇÃO DO PE-155 E FF-0,1. ....	108
TABELA 6. MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO DA IMAGEM PELO ALGORITMO <i>SIMPLECART</i> . ....	110

## LISTA DE ABREVIATURAS OU SIGLAS

AIBO	- Análise de Imagens Baseada em Objetos
ALOS	- <i>Advanced Land Observing Satellite</i>
ASCII	- <i>American Standard Code for Information Interchange</i>
ARFF	- <i>Attribute Relation File Format</i>
C	- denota o conjunto de dados de entrada utilizado na classificação da imagem. A sigla, procedida dos números 01, 02, 03 ou 04 refere-se ao conjunto de dados de entrada utilizado.
CART	- <i>Classification and Regression Tree</i>
CLIMERH	- Centro Integrado de Meteorologia e Recursos Hídricos de Santa Catarina
CS	- Compacidade/Suavidade
EMBRAPA	- Empresa Brasileira de Pesquisa Agropecuária
ENVI	- <i>Environment for Visualizing Images</i>
EPAGRI	- Empresa de Pesquisa Agropecuária e Extensão Rural de Santa Catarina
Es	- Espectrais
ETM	- <i>Enhanced Thematic Mapper</i>
ETM+	- <i>Enhanced Thematic Mapper Plus</i>
FF	- Fator de Forma
FNEA	- <i>Fractal Net Evolution Approach</i>
Fo	- Forma
FOM	- Floresta Ombrófila Mista
FT	- Faixa de Tolerância
GLCM	- <i>Gray Level Co-occurrence Matrix</i>
GLDV	- <i>Grey Level Difference Vector</i>
GPS	- <i>Global Positioning System</i>
HRVIR	- <i>High Resolution Visible-Infrared-</i>
HSMR	- <i>Hierarchical Split Merge Refinement</i>
IAVAS	- Índice de Avaliação da Segmentação
IBAMA	- Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis
Ik	- Ikonos-II
INPE	- Instituto Nacional de Pesquisas Espaciais

IUCN	- <i>International Union for Conservation of Nature</i>
kNN	- <i>k-Nearest Neighbour</i>
LANDSAT	- <i>Land Observation Satellite</i>
LIDAR	- <i>Light Detection and Ranging</i>
MATLAB	- <i>MATrix LABoratory</i>
MCNC	- Matriz de Co-ocorrência dos Níveis de Cinza
MMA	- Ministério do Meio Ambiente, dos Recursos Hídricos e da Amazônia Legal
MODIS	- <i>Moderate Resolution Imaging Spectroradiometer</i>
NDVI	- <i>Normalized Difference Vegetation Index</i>
OBIA	- <i>Object Based Image Analysis</i>
OCE	- <i>Object-Level Consistency Error</i>
PDOP	- <i>Position Dilution of Precision</i>
PE	- Parâmetro de Escala
RFEE	- Reserva Florestal EMBRAPA/EPAGRI
RGB	- <i>Red Green Blue</i>
RUMA	- <i>Relative Ultimate Measurement Accuracy</i>
RVI	- <i>Simple Ratio</i>
SAD-69	- <i>South American Datum of 1969</i>
SAVI	- <i>Soil Adjusted Vegetation Index</i>
SPOT	- <i>Satellite Pour l'Observation de la Terre</i>
SPRING	- Sistema de Processamento de Informações Geográficas
SVM	- <i>Support Vector Machine</i>
Te	- Textura
TM	- <i>Thematic Mapper</i>
UTM	- <i>Universal Transverse Mercator</i>
VDNC	- Vetor das Diferenças dos Níveis de Cinza
WEKA	- <i>Waikato Environment for Knowledge Analysis</i>

## SUMÁRIO

<b>1.</b>	<b>INTRODUÇÃO .....</b>	<b>17</b>
1.1.	MOTIVAÇÃO .....	17
1.2.	ESTABELECIMENTO DO PROBLEMA .....	18
1.3.	CONTRIBUIÇÃO CIENTÍFICA .....	20
1.4.	HIPÓTESE .....	21
1.5.	OBJETIVOS .....	22
1.5.1.	Objetivo Geral.....	22
1.5.2.	Objetivos Específicos .....	22
<b>2.</b>	<b>REVISÃO DE LITERATURA .....</b>	<b>23</b>
2.1.	O SENSORIAMENTO REMOTO APLICADO À ÁREA FLORESTAL.....	23
2.2.	ANÁLISE DE IMAGENS BASEADA EM OBJETOS .....	27
2.2.1.	Segmentação Multiresolução .....	30
2.2.1.1.	Algoritmo “FNEA” ( <i>Fractal Net Evolution Approach</i> ).....	33
2.2.1.2.	Avaliação da Segmentação .....	36
2.3.	ÁRVORES DE DECISÃO .....	40
2.3.1.	Indução de árvores de decisão .....	45
2.3.2.	Ajuste da Árvore .....	52
2.4.	MAPEAMENTO REMOTO DA FLORESTA OMBRÓFILA MISTA.....	53
<b>3.</b>	<b>MATERIAIS E MÉTODOS .....</b>	<b>60</b>
3.1.	ÁREA DE ESTUDO .....	60
3.2.	FLORESTA OMBRÓFILA MISTA.....	62
3.3.	RESERVA FLORESTAL EMBRAPA/EPAGRI .....	64
3.4.	MATERIAIS .....	66
3.5.	METODOLOGIA.....	69
3.5.1.	Segmentação Multi-resolução .....	70
3.5.1.1.	Avaliação Qualitativa .....	72
3.5.1.2.	Avaliação Quantitativa .....	73
3.5.1.2.1.	Otimização do espaço de combinações .....	75
3.5.1.2.2.	Número de Polígonos.....	77
3.5.1.2.3.	Variância da área dos polígonos .....	78
3.5.1.2.4.	Comprimento total de linhas.....	78



3.5.1.2.5. Centróide mais próximo.....	79
3.5.1.2.6. Faixa de coincidência .....	80
3.5.1.2.7. Cálculo do Índice IAVAS .....	82
3.5.1.3. Cálculo dos atributos dos polígonos.....	84
3.5.2. Árvores de decisão.....	84
3.5.3. Seleção de atributos.....	87
3.5.4. Classes de Uso e Cobertura do Solo .....	88
3.5.5. Classificação das Imagens .....	89
3.5.6. Avaliação da qualidade do mapeamento.....	90
<b>4. RESULTADOS E DISCUSSÃO .....</b>	<b>92</b>
4.1. SEGMENTAÇÃO MULTIRESOLUÇÃO .....	92
4.1.1. Avaliação Qualitativa .....	92
4.1.2. Avaliação Quantitativa.....	94
4.2. SELEÇÃO DE ATRIBUTOS E ÁRVORES DE DECISÃO .....	102
4.3. CLASSIFICAÇÃO DAS IMAGENS POR ÁRVORES DE DECISÃO .....	107
<b>5. CONCLUSÕES .....</b>	<b>116</b>
<b>6. RECOMENDAÇÕES FINAIS .....</b>	<b>118</b>
<b>REFERÊNCIAS.....</b>	<b>120</b>
<b>APÊNDICES .....</b>	<b>135</b>

## 1. INTRODUÇÃO

### 1.1. MOTIVAÇÃO

A intensidade da exploração madeireira, desmatamentos e queimadas, substituição da vegetação por pastagens, agricultura e a ampliação das zonas urbanas no sul do Brasil, provocaram uma drástica redução da área de ocorrência original da Floresta Ombrófila Mista a partir dos primeiros anos do Século XX (MEDEIROS *et al.*, 2005). A araucária ou pinheiro (*Araucaria angustifolia*), árvore característica deste ecossistema, representou a principal riqueza madeireira do país por várias décadas, até a década de 1970, quando se sentiu o esgotamento das florestas no Sul do país (CARVALHO, 2006; CARVALHO e NODARI, 2008).

Atualmente, os fragmentos deste tipo florestal estão estimados em 2 a 4% da área de cobertura original (GUERRA *et al.*, 2002; CASTELLA e BRITZ, 2004), a idade das populações remanescentes é senescente e as florestas em estágios primários, ou mesmo avançados, não perfazem mais de 0,7% da área original (MMA, 2002). Por estas razões a Floresta Ombrófila Mista está entre as tipologias mais ameaçadas do bioma Mata Atlântica, considerado prioridade mundial dentre os ecossistemas ameaçados de extinção (MYERS *et al.*, 2000; MMA, 2000).

O manejo florestal de uso múltiplo, o planejamento da paisagem, a preservação e a restauração ambiental são algumas das estratégias para reverter a tendência de fragmentação e degradação da Floresta Ombrófila Mista e a conservação de sua biodiversidade. (ROSOT, 2007; BRITZ, 2007; CASTELLA e BRITZ, 2004; MEDEIROS *et al.*, 2005). Estratégias de manejo e conservação são traçadas a partir do conhecimento do padrão de distribuição espacial e de informações sobre a ecologia e a estrutura espacial das espécies (ANJOS, 1998; ANJOS *et al.*, 2004). Além de levantamentos de campo, dados de sensoriamento remoto têm viabilizado a aquisição de informações de remanescentes florestais, especialmente

com a disponibilidade de imagens de alta resolução espacial, como as do satélite Ikonos-II.

## 1.2. ESTABELECIMENTO DO PROBLEMA

Um dos maiores remanescentes contínuos com vegetação característica da região fitogeográfica Floresta Ombrófila Mista (FOM), parte do domínio da Mata Atlântica (ROSOT *et al.*, 2007(a)), é a Reserva Florestal Embrapa/Epagri (RFEE), no Município de Caçador (SC). A Reserva tem grande importância ambiental e pela representatividade em termos de área, sua vocação está relacionada a (ROSOT *et al.*, 2007(a)): a) fornecer refúgio para espécies vegetais e animais em seus habitats naturais; b) proteger mananciais de água e reservatórios estratégicos; c) proteger solos de processos erosivos e uso indevido; d) manter a estrutura do ecossistema (biodiversidade); e) proporcionar espaço para a recuperação de áreas em diferentes processos ou estágios de perturbação, assim como para ações de manejo que visem a sua sustentabilidade.

A RFEE pertence à Empresa Brasileira de Pesquisa Agropecuária – EMBRAPA e tem servido a estudos que buscam aquisição de conhecimento a respeito da FOM, seu manejo, conservação e o monitoramento de fragmentos deste ecossistema. Ações de pesquisa têm sido conduzidas na RFEE e em seu entorno, tais como a análise da dinâmica e da estrutura da vegetação (LINGNER *et al.*, 2007), o crescimento das espécies (MATTOS *et al.*, 2007; MATTOS *et al.*, 2010); o inventário contínuo e fitossociologia da floresta (RIVERA, 2007; ROSOT *et al.* 2007(a)) a regeneração natural e manejo em áreas de ocorrência de taquara (*Merostachys* sp.) (RIVERA, 2007, ROSOT *et al.*, 2007(a)); recuperação em área degradada por fogo (ROSOT *et al.*, 2007(c)) o ordenamento territorial (RIVERA, 2007) e o zoneamento ambiental (KURASZ, 2005).

Um dos estudos realizado na área da RFEE que tem especial interesse a esta pesquisa foi o de DLUGOSZ (2005), cujos resultados evidenciam a dificuldade de

discriminação das formações florestais da RFEE em seus diferentes estágios sucessionais e níveis de antropização por meio de imagens Ikonos-II. O estudo de DLUGOSZ (2005) levou em consideração sete classes de sub-tipologias florestais, discriminando com exatidão de 51,73% as 11 classes temáticas que compõem a legenda de uso da terra na RFEE, por meio do algoritmo classificador *Bhattacharyya* e aplicado às regiões da imagem segmentada. Para DLUGOSZ (2005), as classes de vegetação retratam formações mistas, que apresentam o agrupamento de mais de uma espécie florestal. Conforme apontado por KLEIN (1960), citado por HERRERA (2009), *“a vegetação da região da araucária não constitui, como pode parecer à primeira vista, uma formação homogênea e contínua. É formada por múltiplas associações e agrupamentos, que se encontram nos mais variados estágios de sucessão”*.

As dificuldades enfrentadas por DLUGOSZ (2005) na discriminação das classes de vegetação da RFEE estão relacionadas à intrincada composição de espécies encontrada nestes ecossistemas, e também às características das imagens Ikonos-II. A maior resolução espacial deste tipo de imagem implica no aumento da variabilidade dos níveis de cinza dos pixels que representam os objetos, o que tem levado à queda de exatidão da classificação com o uso de classificadores tradicionais (HAY *et al.*, 2005; HAY e CASTILLA, 2006). As ferramentas necessárias ao processamento de imagens de alta resolução espacial não estão completamente desenvolvidas e disponíveis e este é, provavelmente, o maior desafio na contribuição do sensoriamento remoto ao manejo florestal sustentável (FRANKLIN, 2001). Face ao exposto, fica clara a necessidade da investigação de métodos alternativos para o processamento e classificação de padrões a partir de imagens Ikonos-II, visando à discriminação de sub-tipologias da Floresta Ombrófila Mista.



### 1.3. CONTRIBUIÇÃO CIENTÍFICA

Estudos voltados ao mapeamento e monitoramento da Floresta Ombrófila Mista a partir de dados de imageamento orbital tem sido conduzidos desde a década de 80. A maioria destes estudos leva em consideração a ocorrência de fragmentos deste ecossistema, não levando em consideração as formações intrínsecas a estes fragmentos (DISPERATTI, 1981; REMPEL, 2000; OLIVEIRA, 2000; BECKER *et al.*, 2004; LUZ, 2005; ALBERGONI, 2011). Recentemente, iniciativas de mapeamento dos remanescentes têm se preocupado em identificar as fases de sucessão da vegetação e o estado de conservação ou antropização em que os remanescentes se encontram (MEDEIROS *et al.*, 2005; BRITEZ, 2007).

No entanto, poucos são os estudos nos quais a classificação de sub-tipologias da Floresta Ombrófila Mista é contemplada, a exemplo das classes temáticas identificadas por DLUGOSZ (2005). Esta é uma informação primordial para o manejo florestal, pois de acordo com MCEVOY (2004) citado por ROSOT (2007): *“florestas sem manejo estão destinadas a desaparecer, sendo gradualmente convertidas para outros usos do solo, bem menos benéficos do que sistemas florestais saudáveis”*. A definição de sub-tipologias é uma estratégia de manejo de florestas naturais bem conhecida, que inclui a composição de espécies, os estágios de desenvolvimento e estratos da floresta, sobre as quais deverão ser aplicados tratamentos silviculturais (ROSOT, 2007).

A utilização de imagens de alta resolução espacial na identificação das sub-tipologias é necessária, já que na maioria das classes são adotadas espécies do dossel da floresta indicadoras do seu estágio sucessional ou nível de antropização. No entanto, a adoção de imagens de alta resolução espacial evidencia a necessidade de técnicas alternativas de processamento. Dentre estes métodos, destaca-se a análise de imagens baseada em objetos, OBIA, do termo em inglês *Object-Based Image Analysis*, definida em 2006 por HAY e CASTILLA. Esta abordagem permite a utilização de atributos de cor, forma, textura e contexto na classificação dos objetos

de imagem, favorecendo a extração de padrões e informações florestais (JU *et al.*, 2005; CHUBEY *et al.*, 2006; MALLINIS *et al.*, 2008; SYED *et al.*, 2005; WULDER *et al.*, 2009; KE *et al.*, 2010; KOVACSOVA e ANTOLOVA, 2010). Outra abordagem que vem demonstrando potencial é a adoção de algoritmos de árvore de decisão para a classificação dos padrões florestais, os quais demonstram exatidão comparável ou superior a outros modelos de extração e representação do conhecimento e classificação de dados (MURTHY, 1995; LIM *et al.*, 1997; HAND, 1997; MARTENS *et al.*, 1998; LIM *et al.*, 2000; MCIVER e FRIEDL, 2002).

A aplicação das abordagens de análise de imagens baseadas em objetos e a classificação de padrões florestais por meio de algoritmos de árvores de decisão são ainda bastante incipientes na discriminação de formações da Floresta Ombrófila Mista (DLUGOSZ, 2005; LUZ, 2005; ALBERGONI, 2011). Adicionalmente, a utilização combinada destas técnicas é recente e tem demonstrado a complementaridade quanto à discriminação de padrões florestais (KE *et al.*, 2010; CHUBEY *et al.*, 2006, LUZ, 2005).

Face ao exposto, esta tese tem como contribuição científica principal a avaliação da combinação de métodos de processamento de imagens digitais, tais como a análise de imagens baseada em objetos e a adoção de algoritmos de árvores de decisão, aplicados à discriminação de sub-tipologias da Floresta Ombrófila Mista.

#### 1.4. HIPÓTESE

Dada a disponibilidade da imagem de alta resolução espacial tomada sobre uma área remanescente de FOM, e a possibilidade de adoção de abordagens alternativas ao processamento e classificação de padrões em objetos de imagem, a presente tese assume a seguinte hipótese: com a adoção da análise de imagens baseada em objetos e a classificação por árvores de decisão é possível discriminar sub-tipologias da FOM a partir da imagem Ikonos-II.

## 1.5. OBJETIVOS

### 1.5.1. Objetivo Geral

Discriminar sub-tipologias da Floresta Ombrófila Mista, por meio da integração de técnicas de análise de imagens baseada em objetos e árvores de decisão, em imagens de alta resolução espacial, a exemplo dos dados adquiridos pelo satélite Ikonos-II.

### 1.5.2. Objetivos Específicos

A adoção de uma metodologia que envolva:

- a) avaliar um método para a seleção de parâmetros de segmentação das imagens por método de avaliação quantitativa;
- b) avaliar procedimentos para a seleção dos atributos espectrais, da forma, da textura e do contexto dos polígonos da segmentação, relevantes à discriminação das sub-tipologias;
- c) investigar o desempenho de algoritmos de indução de árvores de decisão na classificação da imagem;
- d) avaliar a qualidade da classificação comparativamente aos resultados anteriormente obtidos por DLUGOSZ (2005).

## 2. REVISÃO DE LITERATURA

### 2.1. O SENSORIAMENTO REMOTO APLICADO À ÁREA FLORESTAL

O primeiro registro da aplicação de sensoriamento remoto na área florestal que se tem notícia é a reportagem publicada no jornal “*Berliner Tageblatt*”, em 10 de setembro de 1887. A reportagem tratava dos experimentos de um engenheiro florestal alemão, que construiu um mapa de uma área florestal com base em fotografias aéreas, adquiridas a partir de um balão de ar quente (SPURR, 1960<sup>1</sup> *apud* FRANKLIN, 2001).

As fotografias aéreas se estabeleceram como uma ferramenta de reconhecimento na Primeira Guerra Mundial. Desde a era dos sensores remotos aerotransportados, que se desenvolveu ao longo das duas Grandes Guerras, quando a fotointerpretação e a restituição analógica eram a forma adotada para a extração de informações de fotografias aéreas, as técnicas de sensoriamento remoto tem avançado rapidamente (MELESSE *et al.*, 2007).

Na interpretação visual de fotografias digitais, um intérprete pode ver e deduzir o significado do tom, da cor, da textura, do padrão, da forma, e do tamanho dos objetos. A altitude ou elevação podem ser interpretadas e medidas em imagens estereoscópicas. O conhecimento da área e do contexto também pode levar a interpretações eficazes das tipologias florestais. O processo, no entanto, é subjetivo e variável para cada intérprete e entre intérpretes. O objetivo do sensoriamento remoto digital na área florestal tem sido fornecer meios mais objetivos, quantitativos, acurados e precisos para o fornecimento das mesmas informações extraídas pela interpretação de fotografias aéreas, bem como ampla gama de características adicionais que não podem ser acessadas a partir da interpretação visual (KING, 2000).

Com a disponibilidade de dados advindos de diferentes sensores com grande variedade de resolução espacial, temporal e radiométrica, o sensoriamento remoto

---

<sup>1</sup> Spurr, S. A. Photogrammetry and Photo-interpretation. 2ª Ed. Ronald Press, New York. 1960. 472 p.

tem sido, provavelmente, a melhor fonte de dados para o mapeamento e o monitoramento dos recursos naturais e como fonte de informações para a modelagem de processos ambientais de grande escala (MELESSE *et al.*, 2007). Dados de observação da Terra estão disponíveis de forma consistente e em longo prazo em escalas que variam entre domínios locais a globais, complementando e até mesmo substituindo, em alguns casos, a laboriosa coleta de dados em campo (WANG *et al.*, 2010) sendo considerados uma ferramenta fundamental para o monitoramento de recursos florestais (SADER *et al.*, 1990; BOYD e DANSON, 2005). O uso e a cobertura da terra são as características mais notáveis das paisagens e o sensoriamento remoto é a mais importante das fontes de aquisição de dados a respeito dos objetos da superfície terrestre (RONGQUN e DAOLIN, 2011).

O monitoramento de distúrbios florestais de forma acurada, oportuna e freqüente é necessário para o entendimento dos processos e sistemas ecológicos e também para o manejo apropriado dos recursos florestais (POULIOT *et al.*, 2009). O manejo florestal é uma maneira de manter estes recursos na paisagem, de forma que o uso sustentável impeça a sua substituição por outros tipos de uso do solo, mais rentáveis e menos saudáveis (MCEVOY, 2004). O manejo florestal de uso múltiplo pode reverter a tendência de fragmentação e degradação da Floresta Ombrófila Mista, através do uso sustentável destes recursos (ROSOT, 2007). O sensoriamento remoto é considerado a única forma de aquisição de dados biofísicos e bioquímicos da vegetação, em longos períodos de tempo e ao longo de grandes áreas geográficas, indispensáveis para o manejo florestal sustentável (FRANKLIN, 2001). Este é, para o autor, o papel do sensoriamento remoto como uma fonte de informações embasando o manejo florestal sustentável.

Imagens de sensoriamento remoto e técnicas de processamento digital são ferramentas primárias para o mapeamento de tipologias florestais, fundamental para avaliações dos recursos e da biodiversidade (SESNIE *et al.*, 2008). Dados de sensores remotos têm sido utilizados em estudos ambientais, segundo KERR e OSTROVSKY (2003) e BOYD e DANSON (2005), em três principais áreas de

aplicação. A primeira seria a classificação do uso e da cobertura da terra, caracterizando a extensão espacial dos recursos, com finalidades como o mapeamento da cobertura da terra (WASKE e BRAUN, 2009; NA *et al.*, 2010; CLARK *et al.*, 2010); a classificação de tipologias florestais (SIMARD *et al.*, 2000; TOTTRUP, 2007; KE *et al.*, 2010; SESNIE, 2010) ou árvores individuais (YUA *et al.*, 2011); a caracterização e a predição do habitat de espécies raras ou ameaçadas de extinção (BOURG *et al.*, 2005; SESNIE *et al.*, 2008; HELMER *et al.*, 2010); a avaliação da biodiversidade (COOPS *et al.*, 2009) e a classificação da vegetação urbana (TOOKE *et al.*, 2009).

A segunda seria a estimativa de funções e parâmetros dos ecossistemas em diversas escalas, como a estimativa da altura da floresta para estudos da avifauna (HELMER *et al.*, 2010); estimativa de parâmetros de inventário florestal e manejo florestal de precisão, como a idade, a área basal e a altura do talhão, a composição de espécies, o diâmetro de copa e o volume de madeira (WULDER, 1998; CHUBEY *et al.*, 2006; KOVACSOVA e ANTALOVA, 2010) ou a estimativa de biomassa (HELMER *et al.*, 2009).

Por fim, imagens orbitais podem auxiliar na detecção de mudanças, fornecendo estimativas de longo prazo de parâmetros ecológicos que permitem o monitoramento temporal dos ecossistemas, embasando estudos como os de monitoramento da vegetação (ROGAN *et al.*, 2002; FORSTER *et al.*, 2008; SESNIE *et al.*, 2008) e detecção de distúrbios como incêndios ou a ocorrência de pragas e doenças (MARX, 2010; HELMER *et al.*, 2010; MAEDA *et al.*, 2011).

Na área florestal o sensoriamento remoto tem tido um importante papel por muitas décadas, particularmente como uma ferramenta de aquisição de informações sobre localização, extensão, composição e estrutura dos recursos florestais como parte de inventários florestais. Informações de inventário florestal são necessárias para todos os níveis do manejo e planejamento florestal (CHUBEY *et al.*, 2006). Dada a importância econômica e ambiental das florestas, e por serem ecossistemas complexos e de ampla distribuição, as ferramentas e a tecnologia do sensoriamento

remoto são de fundamental importância no monitoramento desses recursos (WULDER, 1998).

O desenvolvimento de técnicas de inventário florestal baseadas no processamento de imagens de satélite multi-espectrais permite a redução de custos e a automação das atividades de interpretação ou extração de informações a partir das imagens (WULDER, 1998). No entanto, a heterogeneidade dos tipos de cobertura florestal, particularmente nos trópicos e a alta complexidade de respostas espectrais advinda destes recursos, pode limitar a capacidade de discriminação de tipologias florestais (BOYD e DANSON, 2005).

Para KING (2000), a análise estatística de dados espectrais de pixels individuais não é capaz de distinguir adequadamente características de interesse em muitas aplicações florestais. O autor aponta as principais limitações desta técnica como sendo: a) interações entre a vegetação, o solo, clima, drenagem e a topografia, que não são adequadamente descritas por dados espectrais do dossel da floresta; b) técnicas estatísticas paramétricas, que dependem de dados independentes e normalmente distribuídos; c) a artificialidade da utilização de conjuntos de pixels amostrais de tamanho arbitrário em uma imagem que não representa os objetos da floresta. Para o autor, as pesquisas envolvendo o sensoriamento remoto de áreas florestais tem se concentrado, a exemplo de outras áreas do conhecimento, na melhoria da análise de dados espectrais e no desenvolvimento de abordagens alternativas, a exemplo das técnicas de classificação não paramétrica, conhecimento contextual e representações baseadas em objetos (KING, 2000). CHUBEY *et al.* (2006) também apontam para a necessidade de abordagens diferentes de análise de imagens digitais, como aquela baseada em objetos, dadas as limitações das técnicas de processamento convencionais baseadas em pixels. Os autores consideram também que uma abordagem de classificação capaz de processar um grande conjunto de dados de entrada é necessária para aproveitar ao máximo o potencial das informações derivadas dos polígonos da imagem, tal como a indução de árvores de decisão (CHUBEY *et al.*, 2006).

As técnicas de extração de informações baseada em objetos e a indução de árvores de decisão, selecionadas para aplicação neste estudo, serão oportunamente abordadas com maiores detalhes.

## 2.2. ANÁLISE DE IMAGENS BASEADA EM OBJETOS

Segundo a enciclopédia de ciências cognitivas, os processos de visualização e percepção humana de objetos dependem do processamento de informações sobre a orientação, o tamanho e a forma dos objetos, e também sobre suas relações espaciais (GOODALE, 1999). De fato, a forma como os objetos são percebidos em imagens depende da individualização dos objetos, da percepção e reconhecimento de seus padrões, e de todas as características dos objetos mencionadas. Ao interpretar visualmente uma imagem, são utilizadas não só as características inerentes à cena, mas também no conhecimento sobre aspectos sociais, culturais econômicos e biológicos a respeito da área de interesse.

A visão humana tende a dividir a imagem, inicialmente, em áreas homogêneas, e características destas áreas são posteriormente analisadas com mais atenção. A divisão da imagem em objetos significativos do mundo real permite que atributos sejam derivados, auxiliando no entendimento da imagem (BLASCHKE *et al.*, 2000). BAATZ e SCHÄPE (1999) também apontam para o fato de que informações semânticas necessárias para a interpretação de imagens estão em grande parte representadas em objetos significativos da imagem e em suas relações mútuas e não em pixels individuais. Sobretudo em imagens de alta resolução espacial, é bastante provável que um pixel e o seu vizinho pertençam a uma mesma classe de uso da terra, ainda que a resposta espectral não seja idêntica, já que neste tipo de imagens, pixels de uma mesma classe apresentam certa heterogeneidade ou textura (BLASCHKE *et al.*, 2000; BLASCHKE e STROBL, 2001).

Na medida em que as técnicas de segmentação são utilizadas para automação da análise de imagens e suas aplicações, esforços em atividades de



interpretação visual e vetorização manual dos objetos da imagem são reduzidos (BAATZ e SCHÄPE, 2000). De fato, os resultados de uma boa segmentação podem ser intuitivamente atrativos, na medida em que resultam no delineamento com “aparência natural” dos polígonos (BLASCHKE *et al.*, 2000).

A segmentação de uma imagem consiste na divisão ou separação da imagem em regiões de atributos similares ou de mesmas características (IEEE, 1990; PRATT, 2007). O objetivo da segmentação de uma imagem é a extração de limites dos objetos ou identificação de regiões definidas por eles, sem nenhum conhecimento *a priori* sobre o que sejam esses objetos. O nível de sub-divisão da imagem depende do problema a ser solucionado, ou seja, a segmentação deve parar quando os objetos de interesse em uma aplicação tiverem sido isolados. (AMITT, 2002).

A segmentação de imagens em níveis de cinza é geralmente baseada em duas propriedades básicas da intensidade dos valores da imagem: descontinuidade e similaridade. Na primeira categoria, a abordagem é particionar a imagem com base em mudanças abruptas na intensidade, como as bordas dos objetos. As abordagens principais da segunda categoria são baseadas no particionamento da imagem em regiões similares de acordo com um conjunto de critérios pré-definidos (GONZALEZ *et al.*, 2004).

Durante a primeira conferência internacional sobre Análise de Imagens Baseada em Objetos (OBIA – Object Based Image Analysis), o termo surge como proposta de uma sub-disciplina da área denominada por GOODCHILD (1990 e 1992) de Ciência de Informações Geográficas, que estaria incluído como uma sub-área do Sensoriamento Remoto. O termo OBIA foi definido por HAY e CASTILLA (2006), na ausência de uma definição formal, como uma disciplina dedicada ao particionamento de imagens de sensoriamento remoto em objetos de imagem significativos, e à avaliação de suas características através de escalas espaciais, espectrais e temporais. Em seu nível mais fundamental, esta abordagem de análise de imagens requer a segmentação, a geração de atributos dos objetos e sua classificação, além

da habilidade de consulta e conexão dos objetos individuais em um mesmo nível e entre diferentes níveis hierárquicos de escala (HAY e CASTILLA, 2006).

O surgimento de técnicas de análise de imagens baseada em objetos (AIBO) se deve a uma série de fatores que surgiram na última década (HAY *et al.*, 2005; HAY e CASTILLA, 2006), dentre os quais:

- a disponibilidade de imagens de alta resolução espacial, trazendo consigo um aumento na variabilidade implícita dos objetos e na queda de exatidão resultante no uso dos classificadores tradicionais;
- a sofisticação crescente das necessidades dos usuários de informações geográficas;
- o reconhecimento dos limites das abordagens baseadas em pixels (já que os mesmos não são objetos geográficos e têm topologia limitada e esta forma de processamento negligencia elementos espaciais de foto-interpretação, como textura, contexto e forma);
- o reconhecimento da necessidade de abordagens em múltiplas escalas para o monitoramento, modelagem e manejo dos ambientes urbanos e rurais.

A disponibilização de imagens de alta resolução espacial e o sucesso comercial do *software* eCognition são apontados por BLASCHKE (2010), em uma abrangente revisão sobre o assunto, como os principais fatores relacionados ao aumento no número de publicações científicas que relatam resultados da aplicação da AIBO ao processamento de dados de sensores remotos orbitais. Diversos outros aplicativos comerciais e também gratuitos ou de código aberto foram desenvolvidos desde então, tais como os citados por BLASCHKE (2010): Feature Analyst, Saga, ENVI Feature Extraction, Erdas Imagine 9.3, Hierarchical Split Merge Refinement (HSMR). Outro sistema interessante e especialmente atrativo, que tem apresentado resultados comparáveis a aplicativos comerciais e é de disponibilização gratuita e código aberto, foi desenvolvido conjuntamente pelo Laboratório de Visão Computacional do Departamento de Engenharia Elétrica da Pontifícia Universidade

Católica do Rio de Janeiro (LVC/PUC-RJ) e pela Divisão de Processamento de Imagens do Instituto Nacional de Pesquisas Espaciais (DPI-INPE). O InterIMAGE é, portanto, um produto gratuito, nacional, e que pode ser adaptado de acordo com as necessidades e aplicações do usuário (COSTA *et al.*, 2008; 2010; CINTRA *et al.*, 2010).

Sub-tópicos de pesquisa emergentes estão relacionados ao desenvolvimento de conceitos de escala e hierarquia; técnicas de segmentação de imagens; técnicas de detecção de mudanças e também técnicas para avaliação da exatidão da classificação, especificamente voltados à AIBO (BLASCHKE, 2010). Ainda segundo o autor, a análise da revisão dos estudos da área permite concluir que a primeira fase da AIBO foi devotada ao desenvolvimento dos aplicativos, algoritmos e da infraestrutura necessária para a geração e exploração dos objetos de imagem. A fase mais recente (desde 2005) está mais relacionada à automação do processamento de imagens; ao reconhecimento de feições e extração de características dos objetos; à incorporação da informação espacial, contextual, da textura e da geometria dos objetos de imagem e à incorporação de sistemas baseados em conhecimento.

#### 2.2.1. Segmentação Multiresolução

A segmentação multi-resolução é assim denominada porque se baseia na possibilidade de geração de objetos primitivos em diversas escalas, permitindo a produção de mais de um nível de objetos e a conexão destes níveis de forma hierárquica. Embutidos nesta rede hierárquica de objetos da imagem, cada um dos objetos conhece seus vizinhos adjacentes, seus sub-objetos e super-objetos. A conexão vertical permite a avaliação da escala e das propriedades de textura dos objetos. A hierarquia permite a representação de informações da imagem em diferentes escalas simultaneamente (BAATZ *et al.*, 2000).

A extração de objetos significativos a partir de imagens, portanto, passa por um conceito que permeia muitas ciências e tem reflexos em diversas áreas do conhecimento e de aplicações: a escala. A segmentação de uma imagem nunca representará objetos significativos em todas as escalas e para todas as aplicações. A definição de objetos significativos, no entanto, não depende somente da finalidade do mapeamento, mas também de definições específicas a respeito dos fenômenos que os geram e, portanto, dependentes das discontinuidades de escala. (BLASCHKE *et al.*, 2000).

A relação das discontinuidades de escala e da continuidade dos processos ecológicos é bastante discutida na ecologia de paisagens, dada a inter-relação e dependência destes fenômenos e seus reflexos no estudo e monitoramento dos recursos naturais. FORMAN (1995) descreveu esta ambigüidade através da visão que uma pessoa tem ao aterrissar em uma nave ou balão. A percepção que se tem é a de descoberta de padrões e mosaicos abruptamente. Muitos mosaicos são quase-estáveis por um momento, separados por rápidas mudanças que representam os “domínios de escalas”. Cada domínio exibe certo padrão espacial, produzido por determinado mecanismo causador ou grupo de processos. Os domínios de escala são, portanto, formados por objetos com diferentes significados ecológicos e devem ser formados por diferentes níveis de segmentação. A segmentação multi-resolução e a classificação baseada em objetos assemelham-se à percepção humana e a forma como extraímos informações de impressões visuais. (BLASCHKE *et al.*, 2000).

Da mesma forma, algumas aplicações de sensoriamento remoto voltam-se à identificação ou ao detalhamento de determinado objeto ou grupos de objetos, olhando com menor interesse para os demais. A escolha da escala espacial e da chamada escala categórica é uma questão essencial na utilização de dados de sensoriamento remoto (JU *et al.*, 2005). A escala espacial refere-se à maneira como o conteúdo de informações da imagem é determinado por sua resolução espacial e a forma como a resolução espacial é manipulada durante o processamento da imagem para a extração de objetos de diferentes formas e tamanhos. A escala categórica

refere-se ao nível de detalhe das categorias utilizadas na classificação (FRANKLIN e WOODCOCK, 1997) e é freqüentemente discutida com referência a uma hierarquia categórica. Por exemplo, uma categoria de cobertura da terra como “vegetação” em um sistema de classificação regional possui uma escala categórica mais grosseira do que sua especificação como “florestas” ou “gramíneas”.

O paradigma dominante na classificação do uso da terra tem sido a classificação em uma única escala espacial e em uma única escala categórica, utilizando-se rótulos de categorias de um único nível, individualizado a partir de uma hierarquia categórica disponível. As aplicações de sensoriamento remoto têm demandado que a classificação da cobertura da terra seja realizada em diferentes escalas, sobretudo em múltiplas escalas categóricas. Esta necessidade pode ser atendida com a geração dos objetos em diferentes escalas e também com diferentes níveis hierárquicos que, através de relações semânticas, suportem as diversas escalas categóricas. Para JU *et al.* (2005), a informação de múltiplas escalas espaciais deve ser incorporada na construção de um mapa, já que os objetos com diferentes escalas categóricas (com rótulos de classe com diferentes níveis de detalhamento) co-existem em um mesmo mapa.

Na geração de um mapa de uso da terra ou na classificação de uma imagem com outra finalidade qualquer, deseja-se uma representação única de todos os objetos de uma imagem, sejam eles objetos menores como casas, árvores, ruas, áreas de cultivo, ou maiores, como florestas, lagos, e cidades. Fica claro que os objetos são mais bem caracterizados e extraídos em diferentes escalas, e utilizando-se de diferentes fontes de informações (SCHIEWE *et al.* 2001).

Diversos autores têm apresentado resultados sobre a comparação das abordagens baseadas em objetos e as tradicionais, apresentando alguns pontos positivos quando objetos de imagem são utilizados como unidades primitivas de processamento. Alguns deles seriam a fidelidade e estabilidade na forma dos objetos, estabelecimento de relações hierárquicas e contextuais entre os objetos da imagem, a diferenciação de um número maior de classes e a obtenção de resultados mais

homogêneos, com número menor de áreas não-classificadas (NEUBERT, 2001; HOFMANN e REINHARDT, 2000; SYED *et al.*, 2005; BLASCHKE *et al.*, 2005).

A metodologia baseada em objetos permite que atributos espectrais, de forma e da textura dos polígonos sejam adicionados à classificação da imagem, incrementando a extração de informações voltadas ao monitoramento do uso da terra em projetos de grande amplitude, como o Europeu Natura 2000 (FORSTER *et al.*, 2008) e também o inventário florestal do Canadá (CHUBEY *et al.*, 2006; WULDER *et al.*, 2009).

#### 2.2.1.1. Algoritmo “FNEA” (*Fractal Net Evolution Approach*)

O algoritmo de segmentação multi-resolução denominado FNEA (*Fractal Net Evolution Approach*) inicia-se com a consideração de que um objeto é formado por um único pixel. A partir dos pixels sementes distribuídos pela imagem, pixels vizinhos podem ser agrupados, de acordo com critérios de homogeneidade previamente definidos. É uma técnica de fusão de regiões que realiza comparações entre pares de pixels vizinhos com o objetivo de minimizar a somatória da heterogeneidade resultante. Em numerosas etapas subseqüentes, objetos menores da imagem são agrupados em objetos maiores. Através deste processo de agrupamento em pares, o procedimento de otimização minimiza a heterogeneidade ponderada dos objetos de imagem resultantes. A cada passo, um par de objetos adjacentes da imagem é fusionado, se a fusão representar o menor crescimento da heterogeneidade definida. Se o menor crescimento exceder o limiar definido pelo parâmetro de escala, o procedimento é encerrado (BAATZ *et al.*, 2000; BLASCHKE e HAY, 2001).

Esta comparação entre o valor de fusão com o parâmetro de escala define, portanto, o critério de parada do algoritmo. O parâmetro de escala é uma medida da mudança máxima na heterogeneidade que pode ocorrer quando dois objetos são agrupados. Este valor é elevado ao quadrado e utilizado como o critério de parada do algoritmo. Quando um possível agrupamento de um par de objetos é examinado, o

valor de fusão entre os dois objetos é calculado e comparado com a potência quadrática do parâmetro de escala (BAATZ *et al.*, 2000).

O critério de heterogeneidade consiste de duas partes: um critério para a cor e um critério para a forma. O critério de cor ou espectral refere-se à alteração na heterogeneidade que ocorre com a fusão de dois objetos de imagem de acordo com a mudança dos pesos do desvio padrão dos valores espectrais em relação aos seus pesos. O critério de forma é um valor que descreve o aperfeiçoamento da forma com relação a dois diferentes modelos que descrevem as formas ideais (BAATZ *et al.*, 2000; BLASCHKE e HAY, 2001).

O valor de fusão total ( $f$ ) é dado pela equação (1) e leva em consideração a heterogeneidade espectral ( $h_{cor}$ ) e a heterogeneidade de forma ( $h_{forma}$ ).

$$f = w \times h_{cor} + (1 - w) \times h_{forma} \quad (1)$$

onde:

$w$  = peso definido pelo usuário para o critério de cor (em detrimento do critério de forma) variando de 0 a 1.

Os desvios padrão em si são ponderados pelo tamanho dos objetos através da aplicação da equação (2) a seguir:

$$h_{cor} = \sum_c w_c \times \left( n_{fusão} \times \sigma_c^{fusão} - (n_{obj1} \times \sigma_c^{obj} + n_{obj2} \times \sigma_c^{obj2}) \right) \quad (2)$$

onde:

$w_c$  = peso da camada de informação

$n_{fusão}$  = número de pixels do objeto após a fusão

$\sigma_c^{fusão}$  = desvio padrão dos pixels do objeto gerado após a fusão

$n_{obj}$  = número de pixels do objeto 1 considerado

$\sigma_c^{obj}$  = desvio padrão dos pixels do objeto 1 considerado

$n_{obj2}$  = número de pixels do objeto 2 considerado

$\sigma_c^{obj2}$  = desvio padrão dos pixels do objeto 2 considerado

O critério de heterogeneidade de forma ( $h_{forma}$ ) inclui dois sub-critérios, referentes à suavidade e compacidade dos polígonos. Baseado nos pesos definidos pelo usuário, a heterogeneidade de forma é calculada pela equação (3).

$$h_{forma} = w_{comp.} \times h_{comp.} + (1 - w_{comp.}) \times h_{suav.} \quad (3)$$

onde:

$w_{comp.}$  = peso atribuído pelo usuário à compacidade da forma dos polígonos

$h_{comp.}$  = heterogeneidade referente à compacidade da forma dos polígonos

$h_{suav.}$  = heterogeneidade referente à suavidade da forma dos polígonos

A mudança na heterogeneidade da forma ocasionada pela fusão é avaliada calculando-se a diferença entre a situação posterior e a situação anterior à fusão. O cálculo dos sub-critérios de heterogeneidade referente à suavidade (equação 4) e à compacidade (equação 5), que resultam na heterogeneidade da forma, é demonstrado a seguir:

$$h_{suav.} = n_{fusão} \times \frac{l_{fusão}}{b_{fusão}} - \left( n_{obj1} \times \frac{l_{obj1}}{b_{obj1}} + n_{obj2} \times \frac{l_{obj2}}{b_{obj2}} \right) \quad (4)$$

$$h_{suav.} = n_{fusão} \times \frac{l_{fusão}}{\sqrt{n_{fusão}}} - \left( n_{obj1} \times \frac{l_{obj1}}{\sqrt{n_{obj1}}} + n_{obj2} \times \frac{l_{obj2}}{\sqrt{n_{obj2}}} \right) \quad (5)$$

onde:

$l_{fusão}$  = comprimento da borda do objeto após a fusão;

$b_{fusão}$  = menor comprimento de borda possível dado por um retângulo envolvente e adjacente ao objeto após a fusão;

$l_{obj1}$  e  $l_{obj2}$  = comprimento da borda dos objetos 1 e 2 respectivamente;

$b_{obj1}$  e  $b_{obj2}$  = menor comprimento de borda possível dado por um retângulo envolvente e adjacente aos objetos 1 e 2 respectivamente

No decorrer do procedimento de segmentação, toda a imagem é segmentada e os objetos da imagem são gerados baseando-se no ajuste de diversos critérios de homogeneidade ou heterogeneidade na cor e na forma. O ajuste do parâmetro de escala influencia indiretamente o tamanho médio do objeto: um maior valor resulta em objetos maiores e vice-versa. Além do parâmetro de escala, os pesos das camadas de informação ou bandas da imagem podem ser ajustados, bem como podem ser realizadas combinações dos critérios heterogeneidade de forma e heterogeneidade de cor (BAATZ *et al.*, 2000).



### 2.2.1.2. Avaliação da Segmentação

A segmentação é uma das etapas mais críticas no processamento digital de imagens (ZHANG, 1996). Apesar do grande esforço dispensado no desenvolvimento de algoritmos para a segmentação de imagens, pouca atenção tem sido dada à avaliação do seu desempenho (ZHANG, 2006; POLAK *et al.*, 2009). A avaliação da segmentação é indispensável para a otimização do potencial e dos resultados dos aplicativos disponíveis e permite descrever o comportamento de determinado algoritmo no tratamento de diferentes imagens (ZHANG, 1997). A qualidade dos resultados da segmentação está relacionada à otimização dos parâmetros de segmentação definidos pelo usuário, que determinam as características dos objetos de imagem (SMITH, 2010). A classificação dos objetos e, por sua vez, a qualidade do mapa final são diretamente influenciados pelos resultados desta etapa (KE *et al.*, 2010).

A identificação da combinação dos parâmetros de segmentação que levam a um resultado ótimo é dificultada sem a adoção de uma metodologia objetiva e rigorosa para sua avaliação (MÖLLER *et al.*, 2007) e tem sido realizada de forma intuitiva, com base em um processo de tentativa e erro (MARPU *et al.*, 2010). Ao testar diversos algoritmos e a configuração de seus parâmetros, ZHANG e GERBRANDS (1994) observaram que pequenas alterações podem causar grande diferença nos resultados da segmentação. De fato, o incremento de exatidão na classificação de imagens segmentadas foi observado quando a seleção dos parâmetros de segmentação foi otimizada (KIM *et al.*, 2009; SMITH, 2010).

De acordo com ZHANG (1996, 2001), os métodos de avaliação de algoritmos ou resultados de segmentação de imagens podem ser analíticos ou empíricos. Os métodos analíticos examinam e avaliam diretamente os algoritmos de segmentação analisando seus princípios e propriedades. Os métodos empíricos julgam indiretamente o algoritmo de segmentação através da mensuração da qualidade dos resultados. Os métodos empíricos podem ainda ser classificados em dois tipos:

métodos de discrepância e métodos de boa qualidade (“goodness”). Nos métodos de boa qualidade algumas propriedades desejáveis nos resultados da segmentação, estabelecidas de acordo com a intuição humana, são avaliados. Nos métodos de discrepância, referências que representam o melhor resultado possível ou desejável são elaboradas e os resultados da segmentação são comparados pela contabilização das diferenças entre ambos. Medidas da discrepância entre a imagem segmentada e a imagem-referência embasam a análise destas diferenças. Maiores valores de discrepância indicam maior erro na segmentação da imagem e, portanto, um desempenho inferior do algoritmo (ZHANG, 1996).

A grande maioria das abordagens quantitativas são basicamente métodos empíricos que usam medidas de discrepância comparando a referência e a segmentação, no entanto poucos são os estudos nos quais imagens de sensores remotos são avaliadas (NEUBERT *et al.*, 2008). POLAK *et al.*, 2009 definiram uma medida de erro para a avaliação do desempenho de algoritmos de segmentação que se baseia em comparações objeto a objeto com a imagem referência e leva em consideração o tamanho, a forma e a posição dos polígonos. O método é denominado “*consistência do erro ao nível de objeto*” (object-level consistency error -OCE) e uma de suas principais vantagens é a penalização da super e sub-segmentação. Uma medida que combina diversos índices de qualidade foi proposta por STURM e WEIDNER (2009) e aplicada a imagens do satélite Quickbird de uma complexa área rural na região oeste da África. A composição da chamada medida de qualidade combinada leva em consideração: critério de atribuição, taxa de qualidade ponderada e o coeficiente de conectividade. MARPU *et al.*, 2010 adotaram uma referência para avaliar anomalias relacionadas à sub-segmentação (segmentação insuficiente) e a super-segmentação (segmentação excessiva) de regiões da imagem. Em casos de super-segmentação a reconstrução do objeto após a correta classificação dos objetos é possível, enquanto que nos casos de sub-segmentação a geometria do objeto não pode ser recuperada. MÖLLER *et al.* (2007) propuseram o uso de métricas dos objetos e de uma métrica de complexidade para a validação da segmentação, de uma forma

em que são combinadas validações locais (para áreas referência amostradas) e globais (de toda a cena), em duas etapas. Imagens pancromáticas do satélite Ikonos-II foram visualmente interpretadas e manualmente segmentadas para a comparação com imagens segmentadas por quatro algoritmos, dois deles baseados em bordas e os outros dois no crescimento de regiões. O número de pixels erroneamente segmentados com relação à imagem referência e a razão entre o número de polígonos na imagem segmentada e na referência foram adotados como medidas de discrepância (CARLEER, 2004). Índices de boa qualidade foram utilizados para avaliar a contribuição da segmentação para a qualidade da classificação enquanto a qualidade posicional das bordas dos objetos foi avaliada por medidas de discrepância. Medidas dos erros de comissão e omissão, identificados nas bordas dos objetos sobrepostos à referência, se demonstraram capazes de identificar a sub-segmentação e a presença de deformações nas bordas dos objetos (RADOUX e DEFOURNY, 2008).

Um método de que se baseia em medidas de características dos objetos como critério de avaliação, comparativamente a uma referência, foi desenvolvido por ZHANG e GERBRANDS (1994) e vem sendo aplicado com sucesso desde então (ZHANG, 1997; OLIVEIRA, 2003; DLUGOSZ, 2005; NEUBERT *et al.*, 2008). Por ser um método consolidado e que apresenta resultados objetivos e quantitativos, a “*medida de exatidão final relativa*” (relative ultimate measurement accuracy - RUMA) foi selecionada para a avaliação e definição dos parâmetros de segmentação neste estudo. Este sistema de avaliação pode ser modificado, incluindo diferentes características dos objetos, consideradas importantes para determinada aplicação. Os valores de RUMA (equação 6) são inversamente proporcionais à qualidade da segmentação: valores menores indicam melhores resultados.

$$RUMA = \left( \frac{R_f - S_f}{R_f} \right) \times 100\% \quad (6)$$

onde:

$R_f$  : característica do objeto obtida da imagem referência

$S_f$  : característica do objeto obtida da imagem segmentada

NEUBERT *et al.* (2006, 2008) adotaram a medida de exatidão final relativa na avaliação do desempenho de sete algoritmos de segmentação de imagens em uma ocasião, atualizando versões e incluindo mais quatro algoritmos posteriormente. Métricas como a variância das discrepâncias da área, do perímetro e do índice de forma dos polígonos da segmentação e da imagem referência foram adotadas. Comparação e inspeção visual com a referência foram complementarmente utilizadas. O método se demonstrou estável e isento de tendenciosidade, observada em outros métodos que não utilizam a referência, tais como métodos empíricos de boa qualidade (NEUBERT *et al.*, 2006; 2008).

OLIVEIRA (2003) se baseou na medida de exatidão final relativa para a proposição de um índice de avaliação da segmentação (IAVAS), modificando o sistema de ZHANG e GERBRANDS (1994), a exemplo do realizado por NEUBERT *et al.*, (2006; 2008), através da inclusão de medidas de discrepância entre a imagem referência e resultados de segmentação. OLIVEIRA (2003) aplicou o índice IAVAS a resultados de segmentação de imagens LANDSAT 7 ETM+ de áreas rurais do norte do Estado de São Paulo. Medidas de discrepância como o número de polígonos, o comprimento total de linhas, a variância da área dos polígonos, o centro de massa mais próximo e a faixa de coincidência foram calculadas com relação a uma referência de campo (obtida em levantamento com GPS diferencial) e uma referência de tela (obtida pela vetorização manual dos polígonos). O índice para avaliação da segmentação (IAVAS) se mostrou eficaz para a identificação dos parâmetros do *software* SPRING que produziram valores coerentes com a imagem de referência (OLIVEIRA, 2003).

A definição dos parâmetros de segmentação no *software* SPRING foi realizada por DLUGOSZ (2005) através da aplicação do índice para avaliação da segmentação de uma cena Ikonos-II (a mesma utilizada neste estudo), na área da Reserva Florestal EMBRAPA/EPAGRI. Algumas alterações foram efetuadas por pelo autor, na obtenção dos valores de algumas métricas, na adoção da distância do

centróide ao invés do centro de massa e na adoção da diferença percentual ao invés da normalização, adotada por OLIVEIRA (2003). Para DLUGOSZ (2005), a metodologia adotada permitiu eliminar a subjetividade na definição da melhor combinação dos parâmetros de segmentação, através da avaliação quantitativa. A formulação, o cálculo e a obtenção das medidas de discrepância e do índice para avaliação da segmentação serão apresentados na Seção 3.5.1.2, já que compõem a metodologia definida para este estudo.

Novas abordagens para a otimização dos parâmetros de segmentação de imagens de sensoriamento remoto, ainda incipientes, envolvem o uso da inteligência artificial para a seleção dos parâmetros, a exemplo dos algoritmos genéticos investigados por COSTA *et al.* (2008). O cálculo da auto-correlação espacial (através do índice de Moran I) e da variância dos objetos da imagem permitiu a KIM e MADDEN (2006) e KIM *et al.*, (2009) a seleção de parâmetros sem a necessidade de uma referência, no entanto permitindo a identificação de sub e super-segmentação, causando impacto positivo na classificação de áreas florestais. SHÖPFER *et al.*, 2008 utilizaram uma ferramenta denominada LIST (*landscape interpretation supoot tool*, disponível no *software* ArcGIS), que analisa relações espaciais entre objetos da imagem e permite a investigação da transição de objetos de forma específica, objeto a objeto. O conceito, denominado “*object fate analysis*” (análise do destino dos objetos), é passível de utilização para a detecção de mudanças e também para a avaliação da exatidão dos objetos da imagem.

### 2.3. ÁRVORES DE DECISÃO

Uma árvore de decisão representa uma função que mapeia cada elemento de seu domínio em um elemento da amplitude de resultados possíveis, que é tipicamente um rótulo de classe ou um valor numérico. É uma representação gráfica para um procedimento de classificação ou de regressão. A cada nó interno da árvore, encontra-se um teste que tem poucos resultados possíveis. Seguindo as ramificações de acordo

com o resultado de cada teste, chega-se a uma folha que contém o rótulo de classe ou um valor numérico (UTGOFF, 1999)

As árvores de decisão fornecem uma estrutura geométrica bastante apropriada para organização de séries de decisões que precisam ser tomadas em determinadas situações (BENDER e WILLIAMSON, 2005). Consistem em um procedimento de classificação que se baseia no particionamento recursivo do espaço amostral (MICHIE *et al.*, 1994) Sendo um dos métodos mais práticos de aprendizado supervisionado, permitem a extração de conhecimento a partir de exemplos de entrada, na forma de amostras de treinamento (YE, 2003). Resultam de um processo de classificação no qual os dados originais são reduzidos a uma árvore de predição que representa um conjunto de regras de decisão (JONES, 2008). A “decisão” tomada pela árvore refere-se à previsão, ou estimativa de um valor de saída, a partir de atributos ou situações descritas para dados de entrada. (RUSSELL e NORVIG, 2003).

O sucesso na aplicação destes algoritmos está relacionado a diversos fatores, que os tornam especialmente atrativos. A forma de representação intuitiva faz com que o modelo resultante seja de fácil compreensão e assimilação (BREIMAN *et al.*, 1984; RUSSELL e NORVIG, 2003). A estrutura explícita da classificação permite que o usuário perceba quais são as características mais importantes na separação das classes e analise quais alterações podem levar a resultados ainda melhores (FRIEDL e BRODLEY, 1997; MARTENS *et al.*, 1998, CHUBEY *et al.*, 2006).

Tanto os dados de entrada quanto os de saída podem ser contínuos ou discretos. Árvores voltadas ao aprendizado de uma função de valores discretos são denominadas árvores de classificação e aquelas voltadas ao aprendizado de uma função contínua, árvores de regressão (RUSSELL e NORVIG, 2003). O fato de serem algoritmos não-paramétricos (GEHRKE *et al.*, 1998; MCIVER e FRIEDL, 2002) permite a integração de dados advindos de diversas fontes e com diferentes formas de distribuição estatística (SESNIE *et al.*, 2008). Também são características favoráveis destes algoritmos a flexibilidade no tratamento de um grande volume de dados, a insensibilidade a ruídos e a capacidade de desempenho mesmo quando poucas

amostras são fornecidas (WASKE e BRAUN, 2009; FRIEDL e BRODLEY, 1997; LIM *et al.*, 2000; PUNIA *et al.*, 2011).

Outro dos principais fatores relacionados à ampla adoção das árvores de decisão é, certamente, a capacidade de obtenção de resultados de maior qualidade, comparativamente a outros modelos de extração do conhecimento e classificação de dados (MURTHY, 1995; LIM *et al.*, 1997; HAND, 1997; MARTENS *et al.*, 1998; LIM *et al.*, 2000; MCIVER e FRIEDL, 2002). Para KING (2000) as árvores de decisão têm sido investigadas como alternativa aos classificadores tradicionais, que requerem dados normalmente distribuídos, resultando em classificações do uso e cobertura da terra de melhor qualidade.

Os algoritmos de árvore de decisão como o C4.5 Random Forest e o *CART* (*Classification and Regression Tree*), além de suas adaptações (WASKE e BRAUN, 2009; SESNIE *et al.*, 2008; MAEDA *et al.*, 2009, LUZ *et al.*, no prelo; PESCH *et al.*, 2011), têm favorecido a conversão de dados de sensores remotos em informações voltadas à conservação da biodiversidade (COOPS *et al.*, 2009); à detecção de mudanças (SILVA *et al.*, 2008); à classificação de ambientes terrestres e marinhos (PESCH *et al.*, 2011); à conservação de espécies raras (BOURG *et al.*, 2005); à identificação de habitat para a avi-fauna (HELMER *et al.*, 2010); e à discriminação de classes da cobertura vegetal em áreas rurais (CLARK *et al.*, 2010), e urbanas (PUNIA *et al.*, 2011).

Na área florestal as árvores de decisão têm sido aplicadas à análise de dados de sensoriamento remoto em diversos contextos, incluindo o delineamento de espécies florestais (SUGUMARAN *et al.*, 2003); estimativa da cobertura arbórea (HANSEN *et al.*, 2002); estimativa da altura das árvores e do diâmetro à altura do peito (DAP); estimativa do volume de toras (YUA *et al.*, 2011); reconhecimento de estágios de infestação de pragas florestais (MARX, 2010); manejo florestal de precisão ou sítio-específico (TAYLOR *et al.*, 2002; KOVACSOVA e ANTALOVA, 2010); detecção e análise de risco de incêndios florestais (MAEDA *et al.*, 2009); estimativa da biomassa aérea viva (SAATCHI *et al.*, 2007) e estimativa de carbono (WATZLAWICK, 2003).



A aplicação do algoritmo *CART* produziu uma melhoria substancial na qualidade do mapeamento do uso e cobertura da terra quando comparado ao método tradicional de máxima verossimilhança (NA *et al.*, 2010). No entanto, o algoritmo *Random Forest* resultou no maior valor de exatidão (91,3%) dentre os algoritmos investigados. WASKE e BRAUN (2009) verificaram aumento de exatidão comparativamente ao algoritmo de máxima verossimilhança, gerando mapas com 84% de acerto. A detecção da ocorrência de uma praga florestal resultou em exatidão do produtor igual a 97% e exatidão do usuário igual a 82% (MARX, 1010). Comparações entre árvores de decisão e o algoritmo de k-vizinhos mais próximos (*k-Nearest Neighbour - kNN*) indicaram a capacidade de redução de erros na estimativa da área basal e do volume por hectare, no inventário florestal da Escócia realizado com auxílio de imagens Spot 4 (MCINERNEY, e NIEUWENHUIS, 2009). Na detecção de mudanças temporais, o processamento das imagens MODIS através da indução pelo algoritmo C4.5 resultou na identificação acurada de 90 21% (MAEDA *et al.*, 2009).

Os resultados de árvores de decisão na discriminação de tipologias florestais complexas como as encontradas nas regiões tropicais e sub-tropicais são sempre inferiores àqueles obtidos para áreas florestais mais homogêneas, como as de determinadas áreas no Hemisfério Norte. Ainda assim, a comparação com outros algoritmos e estimativas de características florestais tem sido animadora também no caso de florestas tropicais e neotropicais. O mapeamento do uso e da cobertura da terra incluindo 32 classes de importância econômica e ecológica em um corredor biológico na Costa Rica resultou em exatidão de 93%+ou-3% (SESNIE *et al.*, 2008). Também na Costa Rica a estimativa da extensão das florestas tropicais ao norte do país apresentou exatidão superior à do algoritmo SVM (*Support Vector Machine*) quando árvores de decisão foram adotadas, com resultado em torno de 86%, permitindo a identificação de 11 tipologias florestais (SESNIE *et al.*, 2010). Os autores consideram satisfatório o resultado pela complexidade de discriminação de tipologias nestes ecossistemas. Árvores de decisão geradas pelo algoritmo See5.0 para a classificação de imagens LANDSAT resultaram em 69% de exatidão na estimativa da



idade e da taxa de acúmulo de biomassa em florestas tropicais secundárias (HELMER *et al.*, 2009). O mapeamento de florestas tropicais e classes de cobertura da terra no centro-norte do Vietnã atingiu exatidão de 81% a partir de imagens do satélite SPOT HRVIR (TOTTRUP, 2007).

Alguns estudos investigaram a integração da análise de imagens baseada em objetos e algoritmos de árvores de decisão para a classificação dos objetos de imagem. CHUBEY *et al.* (2006) utilizaram a segmentação de imagens Ikonos-II utilizando parâmetros de escala igual a 166, cor/forma 0,8, suavidade/compacidade 0,7. Os parâmetros foram selecionados visualmente levando em consideração critérios de qualidade estabelecidos. Métricas dos objetos da imagem e do modelo de elevação da superfície em número de 87 foram calculadas e apenas quatro selecionadas para a classificação das 2 classes de florestas de coníferas, 1 classe de florestas decíduas, 2 classes de vegetação adicionais e também água, areia e rochas. Os autores adotaram algoritmos de árvores de decisão disponíveis no *software* S-Plus para a seleção dos atributos dos polígonos e também para a classificação das amostras de treinamento, resultando na exatidão de 93% e exatidão do produtor variando de 81 a 93% (CHUBEY *et al.*, 2006).

KE *et al.* (2010) combinaram estas técnicas de processamento para a classificação de espécies florestais a partir de imagens de do satélite Quickbird e dados do sensor LIDAR (*Light Detection and Ranging*). Os autores investigaram os passos que envolvem a classificação baseada em objetos, como a criação de objetos de imagem através da segmentação multi-resolução, a extração de métricas dos objetos da imagem e a classificação por árvore de decisão das métricas dos objetos (KE *et al.* 2010). A segmentação da imagem foi avaliada quantitativamente adotando-se a metodologia proposta por MÖLLER *et al.* (2007) e avaliou a similaridade topológica e geométrica entre objetos da segmentação e da referência. Como resultado, os autores selecionaram o parâmetro de escala de 250, relação cor e forma de 0,9 e relação suavidade compacidade de 0,1. Trinta e oito métricas foram calculadas, sendo dezoito delas derivadas da imagem Quickbird, oito dos dados

topográficos oriundos do levantamento LIDAR, sete derivados dos dados de altura LIDAR e cinco das imagens intensidade LIDAR. Por volta de duas a quatro métricas foram selecionadas para cada um dos 180 esquemas de classificação testados, que envolvem as escalas de segmentação e combinações entre os dados LIDAR e as imagens. O resultado de 92% de acerto na classificação das espécies foi obtido quando imagem foi segmentada em conjunto com os dados LIDAR utilizando um parâmetro de escala de 250. O algoritmo de árvore de decisão C5.0 (evolução do C4.5) foi adotado pelos autores.

### 2.3.1. Indução de árvores de decisão

A indução de árvores de decisão se dá de forma recursiva e de cima para baixo, sendo assim representadas. A seleção de um atributo para compor o primeiro nó da árvore, denominado raiz, dá início ao processo. Ramos são gerados a partir deste primeiro nó, através da divisão deste atributo e formação de sub-conjuntos dos intervalos de valores possíveis. O processo é então repetido recursivamente para cada ramo, utilizando somente os sub-conjuntos de observações que atingiram aquele ramo. Quando todas as observações em determinado ramo tiverem a mesma classificação, o processo encerra-se para aquele ramo, formando-se uma terminação denominada folha. A principal decisão a ser tomada, portanto, no processo de indução de árvores de decisão é a determinação dos atributos e os critérios de divisão de cada nó (RUSSELL e NORVIG, 2003; WITTEN e FRANK, 2005). Alguns algoritmos utilizam a média dos valores do atributo como critério de divisão, o que nem sempre pode ser vantajoso. Esta estratégia gera valores que não existem no conjunto de dados de treinamento (HAN e KAMBER, 2001). Outras formas de exploração e descoberta dos valores limite permitem a obtenção de melhores resultados e a geração de árvores mais compactas e eficientes.

Um esquema simplificado de funcionamento do algoritmo de indução de árvores de decisão pode ser descrito como se segue (HAN e KAMBER, 2001):

- o algoritmo é inicializado com três parâmetros:  $D$ , *lista\_de\_atributos*, e *método\_de\_seleção\_de\_atributos*.  $D$  refere-se aos dados das amostras de treinamento e seus respectivos rótulos de classes. O parâmetro *lista\_de\_atributos* é uma lista de atributos que descreve as amostras e *método\_de\_seleção\_de\_atributos* especifica um procedimento heurístico para a seleção de atributos que melhor discrimina as classes das amostras, tais como o ganho de informação ou índice de Gini;

-- a árvore inicia-se em um único nó,  $N$ , que representa as amostras de treinamento  $D$ ;

- se as amostras de  $D$  forem todas de uma mesma classe, então o nó  $N$  torna-se uma folha e é rotulado com aquela classe;

- caso contrário, o algoritmo inicia o *método\_de\_seleção\_de\_atributos* para determinar o melhor critério de divisão. O critério de divisão define qual atributo deve ser adotado como teste no nó  $N$ , determinando a melhor maneira de separar as amostras de treinamento em classes. O critério de divisão também determina os ramos a serem criados a partir do nó  $N$ , contendo os subconjuntos de  $D$  de acordo com o resultado do teste. O critério de divisão é determinado de forma que, idealmente, as partições resultantes em cada galho sejam tão puras quanto possíveis. Uma partição é pura se todas as amostras nela contidas pertencem a uma mesma classe;

- O nó  $N$  é rotulado com o critério de divisão. Um ramo é gerado a partir do nó  $N$  para cada um dos subconjuntos resultantes da aplicação do critério de divisão. As amostras em  $D$  são particionadas, resultando em três cenários possíveis. Assumindo o atributo  $A$  de divisão que tem  $v$  valores distintos,  $\{a_1, a_2, \dots, a_v\}$ , baseados nos dados de treinamento, estes cenários se configuram se:

1)  $A$  é um valor discreto: neste caso, os resultados do teste no nó  $N$  correspondem diretamente aos valores de  $A$  conhecidos. Um galho é criado para cada valor conhecido,  $a_j$ , de  $A$  e rotulado estes valores. A partição  $D_j$  é o sub-conjunto de amostras rotuladas em  $D$  tendo valor  $a_j$  de  $A$ . Se todas as amostras tem o mesmo

valor para  $A$ , então  $A$  não deve ser considerado em uma futura divisão das amostras. Assim sendo, é removido da lista de atributos.

2).  $A$  é um valor contínuo: neste caso, o teste no nó  $N$  tem dois resultados possíveis, correspondentes às condições  $A \leq \text{limiar\_de\_divisão}$  e  $A > \text{limiar\_de\_divisão}$ , respectivamente, sendo que o *limiar\_de\_divisão* é retornado pelo *método\_de\_seleção\_de\_atributos* como parte de critério de divisão. Na prática, o *limiar\_de\_divisão*,  $a$ , é frequentemente tomado como o ponto médio de dois valores adjacentes conhecidos de  $A$  e portanto pode não ser um valor pré-existente de  $A$ , contido nos dados de treinamento. Dois ramos são gerados no nó  $N$  e rotulados de acordo com os resultados anteriores. As amostras são divididas de forma que  $D_1$  contenha o subconjunto de amostras rotuladas em  $D$  para os quais  $A \leq \text{limiar\_de\_divisão}$ , enquanto  $D_2$  contém o restante.

3).  $A$  é um valor discreto e uma árvore binária deve ser produzida (determinado com o método de seleção de atributos ou algoritmo adotado): o teste no nó  $N$  é da forma " $A \in S_A$ ?".  $S_A$  é o subconjunto da divisão de  $A$ , resultante da aplicação do *método\_de\_seleção\_de\_atributos* como parte do critério de divisão. É um subconjunto de valores conhecidos de  $A$ . Se determinada amostra tem valor  $a_j$  de  $A$  e se  $a_j \in S_A$ , o teste no nó  $N$  é satisfeito. Dois ramos são gerados a partir do nó  $N$ , contendo os subconjuntos  $D_1$  (subconjunto de  $D$  que satisfaz o teste) e  $D_2$  (subconjunto de  $D$  que não satisfaz o teste);

- o algoritmo usa o mesmo processo recursivamente para formar uma árvore de decisão para as amostras em cada partição resultante,  $D_j$ , de  $D$ .

- a divisão recursiva se encerra somente quando alguma das três condições de finalização for verdadeira, retornando-se a árvore de decisão resultante:

- 1) todas as amostras de treinamento  $D$  (representadas no nó  $N$ ) pertencem à mesma classe, ou

- 2) não existem atributos remanescentes a partir dos quais as amostras de  $D$  poderiam ser posteriormente divididas. Neste caso, o princípio da maioria é empregado, convertendo-se o nó  $N$  em uma folha e rotulando-a com a classe mais

frequente em  $D$ . Alternativamente, pode ser armazenada a distribuição das classes das amostras no nó.

3). Não existem amostras para um dado galho, isto é, uma partição  $D_j$  está vazia. Neste caso, a folha é criada com a maioria das classes em  $D$ .

A definição da ordem de inclusão dos atributos na árvore é dada pela avaliação de uma propriedade estatística denominada “*ganho de informação*”. O ganho de informação de um atributo  $A$  em um conjunto de observações de treinamento  $S$  é dado pela equação (7) (KONAR, 2000):

$$\text{Ganho}(S, A) \equiv \text{Entropia}(S) - \sum (|S_V|/|S|) \text{Entropia}(S_V) \quad (7)$$

onde:

$V \in$  valores de  $A$ ;

$|S_V|$  denota o sub-conjunto de  $S$  para os quais o atributo  $A$  tem valor  $V$ ;

$|X|$  denota cardinalidade de  $x$  para  $x \in \{S_V, S\}$ .

O ganho de informação (equação 7) depende de um parâmetro denominado entropia. Para uma classificação de um conceito alvo ou uma decisão lógica (*booleana*), dada uma coleção de  $S$  observações positivas e negativas, a entropia de  $S$  é dada pela equação (8). Quando o classificador tem uma amplitude de saída que assume  $c$  diferentes valores, a *Entropia* de  $S$  será dada pela equação (9) (KONAR, 2000).

$$\text{Entropia} \equiv -\text{pos} \log_2(\text{pos}) - \text{neg} \log_2(\text{neg}) \quad (8)$$

onde:

$\text{pos}$  e  $\text{neg}$  denotam proporções de observações positivas e negativas em  $S$ .

Nota: para o cálculo da entropia, define-se  $0 \log_2(0) = 0$

$$\text{Entropia}(S) = \sum_{i=1}^c -P_i \log_2(P_i) \quad (9)$$

onde:

$P_i$  = denota a proporção de  $S$  pertencente à classe  $i$ .

A construção de uma árvore de decisão binária é exemplificada de acordo com os dados da Tabela 1, que apresenta observações de atributos relacionados ao problema de aprendizado do voo de pássaros (KONAR, 2000).

TABELA 1. DADOS DE OBSERVAÇÕES DE ATRIBUTOS RELACIONADOS AO PROBLEMA DE APRENDIZADO DO VÔO DE PÁSSAROS

FONTE: KONAR, 2000.

Observação	Nº de asas	Asas quebradas	Status de sobrevivência	Área da asa/ Peso da ave	Vôo
1	2	0	vivo	2,5	verdadeiro
2	2	1	vivo	2,5	falso
3	2	2	vivo	2,6	falso
4	2	0	vivo	3,0	verdadeiro
5	2	0	morto	3,2	falso
6	0	0	vivo	0,0	falso
7	1	0	vivo	0,0	falso
8	2	0	vivo	3,4	verdadeiro
9	2	0	vivo	2,0	falso

Considerando os dados da Tabela 1, verifica-se que  $S$  tem 3 observações positivas e 6 negativas, portanto a aplicação da equação (8) determina a entropia de  $S$  como:

$$\text{Entropia } [3+, 6-]: = -(3/9) \log_2 (3/9) - (6/9) \log_2 (6/9) = -(1/3) [\log_2 (4/27)] = 0,9179$$

Por sua vez, no exemplo sobre o voo dos pássaros, o cálculo do Ganho ( $S$ , status de sobrevivência) para  $S = [3+, 6-]$ ,  $S_{\text{vivo}} = [3+, 5-]$  e  $S_{\text{morto}} = [0+, 1-]$  se daria substituindo-se os valores pertinentes na equação (7):

$$\text{Ganho } (S, \text{status de sobrevivência}) = \text{Entropia } (S) - \sum (|S_V|/|S|) \text{Entropia } (S_V)$$

onde:

$$V \in \{\text{vivo}, \text{morto}\}$$

$$\begin{aligned} \text{Ganho}(S, \text{status de sobrevivência}) = & \text{Entropia}(S) - \left( \frac{|S_{\text{vivo}}|}{|S|} \right) \text{Entropia } (S_{\text{vivo}}) - \\ & (|S_{\text{morto}}|/|S|) \text{Entropia } (S_{\text{morto}}) \end{aligned}$$

onde:

$$|S_{\text{vivo}}| = 8, |S_{\text{morto}}| = 1, |S| = 9$$

$$\text{Entropia}(S_{\text{vivo}}) = \text{Entropia}[3 + ,5 -] = -\left(\frac{3}{8}\right)\log_2\left(\frac{3}{8}\right) - \left(\frac{5}{8}\right)\log_2\left(\frac{5}{8}\right) = 0,5835$$

$$\text{Entropia}(S_{\text{morto}}) = \text{Entropia}[0 + ,1 -] = -\left(\frac{0}{1}\right)\log_2\left(\frac{0}{1}\right) - \left(\frac{1}{1}\right)\log_2\left(\frac{1}{1}\right) = 0$$

Assim sendo, substituindo os valores acima na equação do Ganho, tem-se:

$$\text{Ganho}(S, \text{status de sobrevivência}) = 0,9179 - \left(\frac{8}{9}\right) \times 0,5835 = 0,3992$$

Pode ser observado na Tabela 1 que vôo = verdadeiro se (no. de asas = 2)  $\wedge$  (asas quebradas=0)  $\wedge$  (status de sobrevivência = vivo)  $\wedge$  ((área de asa/peso) da ave  $\geq 2,5$ ) é verdadeiro. Assim, pode-se escrever a seguinte regra de decisão: Vôo = (no. de asas = 2)  $\wedge$  (asas quebradas = 0)  $\wedge$  (status de sobrevivência = vivo)  $\wedge$  ((área de asa/peso) da ave  $\geq 2,5$ ). A árvore de decisão correspondente à última expressão é dada na Figura 1.

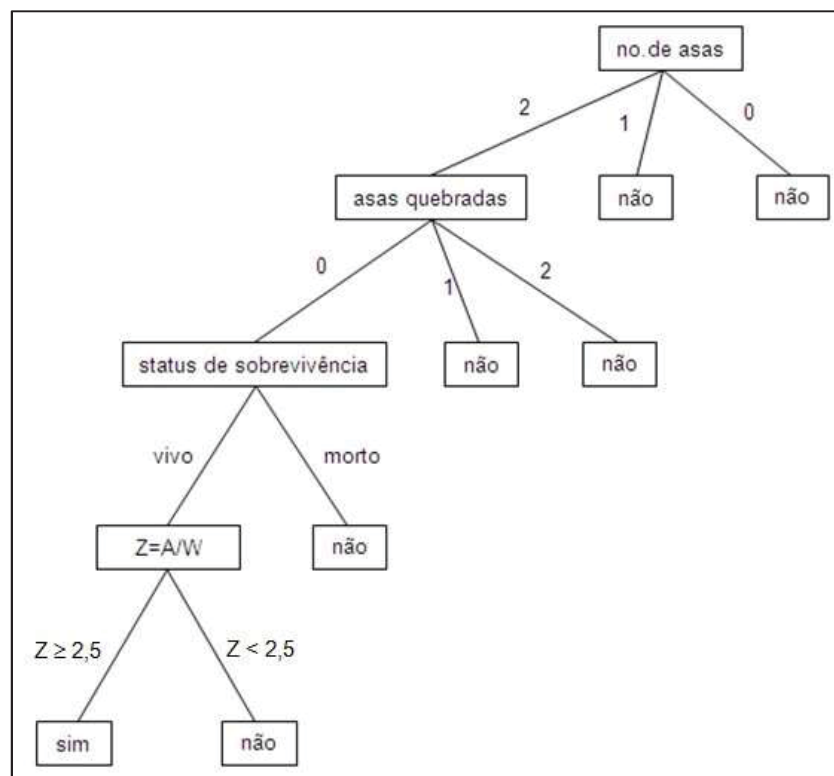


FIGURA 1. UMA ÁRVORE DE DECISÃO QUE DESCREVE A OBSERVAÇÃO DO VÔO DE UM PÁSSARO, COM CADA UMA DAS FOLHAS DESCREVENDO OS VALORES BINÁRIOS DE VÔO.

FONTE: ADAPTADO DE KONAR, 2000.

Nesta figura, se o número de asas for menor do que 2, vôo = falso aparece no próximo nível. Se o número de asas = 2, então é testado: quantas asas estão quebradas. Se a resposta for 0, checa-se o status de sobrevivência = vivo, caso contrário declara-se vôo = falso. Posteriormente, se o status de sobrevivência for = vivo, checa-se se  $Z=A/W \geq 2,5$ . Em caso afirmativo, vôo=verdadeiro, caso contrário, vôo é declarado falso.

O objetivo principal dos algoritmos de árvore de decisão não reside somente na elaboração de uma estrutura de representação que demonstre de forma exaustiva todos os conjuntos de testes possíveis de serem realizados para atingir a decisão que defina cada entrada. Isto levaria a árvore a “memorizar” todas as decisões, ao invés de aprender ou extrair padrões a partir dos exemplos de treinamento, impedindo a extrapolação das decisões a exemplos desconhecidos, ou novas ocorrências. O objetivo principal é o de encontrar a menor das árvores de decisão possível, que seja consistente com os exemplos de treinamento. A idéia embutida nestes algoritmos é a de testar o atributo mais importante em primeiro lugar, entendendo-se por mais importante aquele que faz determina ou mais influi na classificação de determinado exemplo. Assim, pode-se atingir uma classificação correta com um pequeno número de testes, significando que todos os caminhos da árvore serão curtos e a árvore como um todo será pequena (RUSSELL e NORVIG, 2003).

O conhecimento representado por uma árvore de decisão pode ser extraído e representado na forma de regras de classificação do tipo IF-THEN. Uma regra é criada para cada caminho, da raiz às folhas. Cada par de valores de atributos ao longo de determinado caminho forma uma conjunção na regra antecedente (parte IF). A folha contém a previsão da classe, formando a regra conseqüente (parte THEN). As regras IF-THEN podem ser de mais fácil compreensão, particularmente se a árvore de decisão for muito grande (HAN e KAMBER, 2000).



### 2.3.2. Ajuste da Árvore

As árvores de decisão são de fácil compreensão e interpretação; contudo, podem tornar-se bastante complexas se forem consideradas, por exemplo, bases de dados com centenas de variáveis ou atributos e variáveis de resposta com dezenas de classes de saída. Uma árvore assim pode ser bastante intrincada (EDELSTEIN, 1999). Além disso, muitos dos ramos refletirão anormalidades nos dados de treinamento, devido a ruídos ou *outliers*. O método de ajuste da árvore, também denominado “poda”, trata do problema de *overfitting* dos dados, aplicando medidas estatísticas para remover os galhos menos confiáveis. Árvores podadas tendem a ser menores e menos complexas e são, portanto, mais facilmente compreendidas. Elas são usualmente mais rápidas e melhores na classificação correta de dados independentes do que as árvores não podadas (HAN e KAMBER, 2001).

Na prática, a construção de uma árvore de classificação se dá em duas fases. Na primeira fase, a fase de crescimento, uma árvore extremamente grande é construída a partir dos dados de treinamento. Na segunda fase, a fase de *poda*, o tamanho final da árvore é definido com o objetivo de minimizar o número de galhos e, em última análise, o tamanho da árvore (YE, 2003).

Existem duas abordagens comuns para a poda de árvores de decisão: pré-poda e pós-poda. Na abordagem pré-poda, a árvore é podada interrompendo sua construção prematuramente (é tomada a decisão de não particionar ou dividir ainda mais o sub-conjunto de amostras de treinamento em um dado nó). Com a finalização, o nó torna-se uma folha. A folha pode conter a classe mais freqüente entre o conjunto de amostras ou a probabilidade de distribuição das amostras (WITTEN e FRANK, 2005).

Quando a árvore está sendo construída, medidas como a significância estatística, o ganho de informação e o índice Gini, dentre outras, podem ser utilizadas para avaliar a qualidade de um particionamento ou divisão. Se o particionamento das amostras em dado nó poderia resultar em uma divisão que se localiza abaixo de

determinado limiar pré-definido, então o posterior particionamento de determinado conjunto de amostras é interrompido. Existem dificuldades, no entanto, na escolha do limiar apropriado. Um limiar alto pode resultar em uma árvore muito simplificada, enquanto que um limiar baixo pode resultar em pouca simplificação (HAN e KAMBER, 2001).

A segunda e mais comum abordagem é a pós-poda, que remove atributos das sub-árvores a partir de uma árvore completamente construída. Uma sub-árvore em um dado nó é podada pela remoção de seus galhos e a sua substituição por uma folha. A folha é rotulada com a classe mais freqüente dentre aquelas contidas na sub-árvore que está sendo substituída (HAN e KAMBER, 2001).

O método de poda implementado no algoritmo C4.5 (QUINLAN, 1986), utilizado na realização deste trabalho, é denominado poda pessimista, e é similar ao método de custo-complexidade implementado no algoritmo *CART* (BREIMAN, 1984). Este método utiliza o erro da estimativa para tomar as decisões relacionada à poda da sub-árvore. A poda pessimista usa o conjunto de amostras de treinamento para estimar as taxas de erro. Como ocorre certa sub-estimativa dos erros quando amostras de treinamento são utilizadas, o método de poda pessimista ajusta as taxas de erro adicionando uma penalidade, sendo por isso denominado pessimista (HAN e KAMBER, 2001).

## 2.4. MAPEAMENTO REMOTO DA FLORESTA OMBRÓFILA MISTA

Poucas são as iniciativas da aplicação de imagens de sensores remotos à caracterização espectral e ao desenvolvimento de metodologia apropriada à classificação da Floresta Ombrófila Mista (FOM), a despeito da importância deste ecossistema, de sua beleza cênica, de seu valor econômico ou de quaisquer outras funções ou serviços intrínsecos a este ambiente. Uma das primeiras iniciativas de desenvolvimento metodológico para a discriminação de sub-tipologias da FOM, senão a primeira delas foi protagonizada por DISPERATI (1981), que realizou experimentos

voltados ao mapeamento deste ecossistema por meio de imagens LANDSAT II. Foram definidas quatro classes, de Floresta de Araucária densa e com baixa densidade de Araucária, outras florestas e áreas não florestais. Valores próximos a 83% de exatidão foram verificados, atingindo mais de 90% para todas as classes, com exceção das Florestas com Araucária em baixa densidade, com valores próximos a 50%, quando a imagem foi classificada por algoritmos supervisionados. Resultados piores foram obtidos quando a classificação foi realizada pelo método não supervisionado, resultando em 65,82% de exatidão.

No ano de 2000, OLIVEIRA pesquisou o relacionamento entre a vegetação e imagens de sensoriamento remoto visando à avaliação e ao monitoramento da Floresta Ombrófila Mista e seus ecossistemas associados. As propriedades de reflectância e as assinaturas espectrais da Floresta Ombrófila Mista, de plantações de *Araucaria angustifolia*, de plantações de *Pinus elliottii* e de plantações de *Pinus taeda* foram analisadas e caracterizadas. O autor utilizou componentes principais para a redução da confusão espectral entre florestas plantadas de *Pinus taeda*. Modelos lineares de mistura espectral foram utilizados para a detecção e identificação de *A. angustifolia* ao nível de sub-pixels. O índice de vegetação de diferença normalizada contribuiu para o sucesso na detecção de mudanças da biomassa. A autora aponta o uso destas técnicas no processo de diferenciação de imagens como uma metodologia promissora de sistema de monitoramento deste ecossistema.

Imagens de sensores remotos orbitais foram adotadas para a geração de mapas de uso e cobertura da terra, em áreas de ocorrência de Floresta Ombrófila Mista. CASTELLA e BRITEZ (2001) realizaram um diagnóstico dos remanescentes de FOM no Estado do Paraná, com imagens LANDSAT TM, visando à conservação do bioma. Também com uma abordagem conservacionista, Medeiros *et al.* (2005), realizaram levantamentos de áreas prioritárias para a criação de unidades de conservação no Estado do Paraná. Imagens LANDSAT e Spot foram utilizadas em mapeamentos da ocorrência de remanescentes e imagens Ikonos-II forneceram

informações mais detalhadas sobre os principais fragmentos levantados na etapa anterior.

A interpretação visual e o delineamento manual dos polígonos de uso e cobertura da terra foram adotados em algumas aplicações, dada a dificuldade de obtenção de resultados apropriados com o processamento digital de imagens. ASCENÇO (2003) analisou a fragmentação dos ambientes florestais em assentamentos rurais no interior do Estado do Paraná e KURASZ (2005) se utilizou de imagens Ikonos-II para o delineamento das feições de uso e cobertura da terra no entorno da Reserva Florestal Embrapa/Epagri, em Caçador (SC).

BECKER *et al.*, (2004) utilizaram imagens LANDSAT TM 5 de 1995 para o mapeamento da cobertura da terra voltado à análise do estado de conservação da vegetação da Bacia do Rio Maquiné, no Rio Grande do Sul. Imagens Cbers-2B e Ikonos-II foram utilizadas para a detecção de copas de *Araucaria angustifolia*. As imagens foram fusionadas e sua primeira componente principal passou pela segmentação no *software* Spring, com limiares de similaridade e área de 5 e 10, respectivamente, selecionados com base em análise visual da qualidade do delineamento das copas de *A. angustifolia*. A classificação não supervisionada *Isoseg* foi aplicada aos polígonos da imagem, resultando em 75% de acerto (SILVA *et al.*, 2009).

Índices de Vegetação por Diferença Normalizada (NDVI), gerados pelo sistema MODIS-Terra e dados meteorológicos do período de Fevereiro de 2000 a Fevereiro de 2006 foram utilizados por ROSEMBACK (2007) e ROSEMBACK *et al.* (2010) como base para a análise da dinâmica da cobertura vegetal na Região Sul do Brasil. Técnicas de detecção de mudanças baseadas em análises estatísticas, como a análise da distribuição e do histograma e a correlação dos dados meteorológicos e aqueles oriundos das imagens foram adotadas, permitindo a investigação da correlação entre o comportamento da vegetação e variáveis climáticas em escala regional.

REMPEL (2000) aplicou a técnica de classificação supervisionada a imagens LANDSAT TM5 para a identificação de feições da mata nativa original (Floresta Estacional Decidual e Floresta Ombrófila Mista), vegetação nativa secundária em estágio primário, florestas artificiais, campo, florestas plantadas, solo exposto e área de plantio. O mapa de uso e cobertura da terra, obtido pela classificação da imagem, não teve sua qualidade avaliada por meio da exatidão, destinando-se à determinação da evolução da mata nativa no período de 1985 e 1995.

Algumas iniciativas da estimativa remota de características da Floresta Ombrófila Mista, por meio de imagens do satélite Ikonos-II estão relacionadas à estimativa de macro e micronutrientes (CANAVESI, 2004; ACCO, 2004; CANAVESI e KIRCHNER, 2006) e a estimativa de biomassa e carbono (WATZLAWICK, 2003).

Desde 2002 a Embrapa Florestas tem desenvolvido pesquisas na RFEE voltadas ao mapeamento, monitoramento e zoneamento ecológico da área da Reserva e de seu entorno (ROSOT *et al.*, 2007(a)). Resultados das atividades envolvendo o processamento de imagens orbitais para a extração de informações do uso e da cobertura da terra, resultantes destes esforços de pesquisa, serão brevemente sumarizados a seguir, dada a relevância e a correlação com o estudo apresentado neste trabalho.

O estudo de DLUGOSZ (2005) avaliou a possibilidade de identificação de sub-tipologias florestais presentes no fragmento de Floresta Ombrófila Mista contido na RFEE, visando desenvolver uma metodologia para o mapeamento dos remanescentes deste ecossistema de forma rápida, com baixo custo e precisão aceitável. Imagens do satélite Ikonos-II de 2004, as mesmas disponibilizadas para este estudo, foram segmentadas e classificadas pela abordagem orientada a regiões, técnicas de processamento disponíveis no *software* Spring, desenvolvido pelo INPE (Instituto Nacional de Pesquisas Florestais). Na segmentação da imagem pela técnica de crescimento de regiões foram adotados os limiares de similaridade de 35 e área 1200, definidos por análises quantitativas e qualitativas dos resultados da segmentação. A análise quantitativa adotou o índice de Avaliação da Segmentação

(IAVAS) com algumas modificações, baseado no mesmo índice adotado neste trabalho, descrito em detalhes na Seção 3.5.1.2. A imagem segmentada foi submetida aos algoritmos de classificação “*Isoseg*” e “*Bhattacharyya*”, tendo este último apresentado os melhores resultados de exatidão, com valor de 0,43 para o índice de Kappa e 51,73% de exatidão. As classes de uso e cobertura da terra definidas neste mapeamento, adotadas no presente estudo e descritas em detalhes na Seção 3.4, são: “predominância de araucária”, “baixa densidade de araucária”, “canelas”, “bracatinga/canela guaicá”, “vassourão”, “vassourinha”, “vegetação de solos úmidos”, “taquara”, “várzea”, “lago”, “solo exposto”, “estrada”, “agricultura/fruticultura”. Esta classificação baseia-se na presença de espécies indicadoras de estágio sucessional com fisionomia arbustiva a arbórea que compõem o dossel da floresta. A classe “predominância de araucária” apresentou a maior exatidão do produtor, 76,39% e as demais sub-tipologias florestais apresentaram valores abaixo de 50% para a exatidão do produtor. Para o autor, estes resultados foram obtidos possivelmente por estas sub-tipologias retratarem classes de vegetação mista que apresentam o agrupamento de mais de uma espécie florestal. Grande confusão ocorreu entre as classes “bracatinga” e a classe “canelas”, e entre as classes “canelas” e “predominância de araucária”. As classes de “taquara” e “vassourão” foram sub-estimadas pelo classificador, ou seja, apresentaram erros de comissão inferiores aos de omissão, diferente do que ocorreu com as demais.

O autor recomenda a utilização de algoritmos segmentadores previamente à classificação da imagem, a avaliação da segmentação pelo índice IAVAS e considera que melhores resultados poderiam ser alcançados com o uso de algoritmo segmentador FNEA (*Fractal Net Evolution Approach*), pelo fato de permitir a extração de características dos objetos e do seu contexto. Esta recomendação deu origem à idéia deste trabalho de pesquisa, que adota o algoritmo recomendado para a segmentação da imagem e a metodologia de avaliação quantitativa da segmentação por meio do cálculo do índice IAVAS no qual DLUGOSZ (2005) se baseou.

Imagens do satélite ALOS foram utilizadas para avaliar o uso de diferentes algoritmos classificadores no mapeamento do uso da terra e classes de vegetação na RFEE (LUZ, 2005). Os algoritmos “*Bhattacharyya*” e *J48* de árvore de decisão foram comparados para a classificação das imagens originais e secundárias, como componentes principais, NDVI, SAVI, RVI, e medidas de ocorrência e co-ocorrência da textura das imagens, totalizando 61 imagens. Para o algoritmo “*Bhattacharyya*” foi necessário reduzir o número de variáveis para 6. A segmentação da imagem foi efetuada no *software* SPRING pelo algoritmo de crescimento de regiões, utilizando limiares de similaridade e área iguais a 5 e 180, respectivamente. A classificação por árvore de decisão apresentou exatidão elevada, igual a 97% e Kappa de 0,966 enquanto que a classificação por *Bhattacharyya* atingiu 79% e coeficiente Kappa 0,755. Nos resultados das classes individuais para exatidão do usuário e do produtor o desempenho do algoritmo de árvore de decisão na separabilidade das classes também foi superior. A autora também recomenda, a exemplo de DLUGOSZ (2005), a utilização da segmentação FNEA do *software* eCognition como forma de geração de objetos e atributos dos polígonos da imagem.

A mais recente atividade de pesquisa envolvendo a área em que a RFEE está inserida foi a de NASCIMENTO (no prelo), que estudou o entorno da RFEE com o intuito de avaliar a vulnerabilidade a que a Reserva está submetida e avaliar os fatores que a afetam em termos de pressões externas e internas. Uma análise da ecologia da paisagem do entorno foi realizada, bem como a avaliação da dinâmica da fragmentação e das relações da reserva com a matriz em que está inserida. Estas análises tiveram como subsídio o mapa de uso e cobertura da terra. Imagens do satélite Alos, sensores AVNIR-2 e PRISM, adquiridas em 2006, foram segmentadas e classificadas por meio da análise de imagens baseada em objetos. Classes de agropecuária, água, áreas construídas, floresta nativa e reflorestamento foram mapeadas, incluindo também áreas de ocorrência de nuvens e sombras como classes auxiliares. O *software* eCognition foi utilizado e métricas dos polígonos da segmentação foram calculadas, auxiliando na separabilidade espectral e permitindo a

aplicação de funções Fuzzy na classificação dos objetos. A exatidão obtida foi de 66,6% e o índice Kappa igual a 0,61%. Para a elaboração do mapa final, polígonos erroneamente classificados passaram por edição vetorial para a correção de erros temáticos (NASCIMENTO, no prelo).



### 3. MATERIAIS E MÉTODOS

#### 3.1. ÁREA DE ESTUDO

A Reserva Florestal EMBRAPA/EPAGRI (RFEE), foco deste estudo, localiza-se no Município de Caçador, centro-oeste do Estado de Santa Catarina. O município limita-se ao norte com o Município de Calmon; a leste com Lebon Régis; a sudeste com Rio das Antas; ao sul com Videira e Arroio Trinta; a sudoeste com Macieira; a oeste com Água Doce e a noroeste com General Carneiro, no Estado do Paraná (THOMÉ, 1978<sup>2</sup> *apud* KURASZ 2005).

A RFEE compreende uma área de 1157,48 hectares e se localiza entre as coordenadas geográficas 26°50'32,69"S e 26°52'36,73"S; 50°54'51,69"N e 51°58'40,36"N, conforme apresentado na Figura 2.

A RFEE está inserida na bacia hidrográfica do Rio Uruguai, sub-bacia do Rio do Peixe, onde predominam as rochas efusivas, sobretudo o basalto (EMBRAPA/EPAGRI, 1997<sup>3</sup> *apud* KURASZ, 2005). Parte da bacia do Rio do Peixe, a oeste da Serra Geral, é coberta por rochas basálticas (basaltos e diabásios) THOMÉ, 1978<sup>2</sup> *apud* KURASZ, 2005).

O Centro Integrado de Meteorologia e Recursos Hídricos de Santa Catarina (CLIMERH) possui uma estação meteorológica de monitoramento contínuo localizada na área da Reserva, permitindo uma caracterização bem definida do clima. O Subtropical úmido mesotérmico e definido como tipo *Cfb* segundo Köppen é caracterizado como temperado úmido, sem estação seca, com verões frescos e apresentando invernos rigorosos com geadas severas (CALDATO *et al.*, 1999<sup>4</sup> *apud* DLUGOSZ, 2005). A temperatura média anual é de 16,6°C, sendo a máxima média

---

<sup>2</sup> Thomé, N. Isto é Caçador. Estudo geográfico do Município. Caçador: Imprensa Universal. 1978. 1ª ed. 177p.

<sup>3</sup> EMBRAPA/EPAGRI. **Reserva Florestal da EMBRAPA/EPAGRI de Caçador - Plano Diretor**. Caçador, SC, 20p. 1997.

<sup>4</sup> CALDATO, S.L.; LONGHI, S.J.; FLOSS, P.A. Estrutura populacional de *Ocotea porosa* (Lauracea) em uma floresta ombrófila mista em Caçador (SC). **Revista Ciência Florestal**. Universidade Federal de Santa Maria, v.9, n.1, p. 89-101. 1999.

de 11°C no mês de junho. A temperatura absoluta máxima de 38°C foi registrada em 6 de janeiro de 1948 e a mínima, de -14°C, ocorreu no dia 11 de junho de 1952.

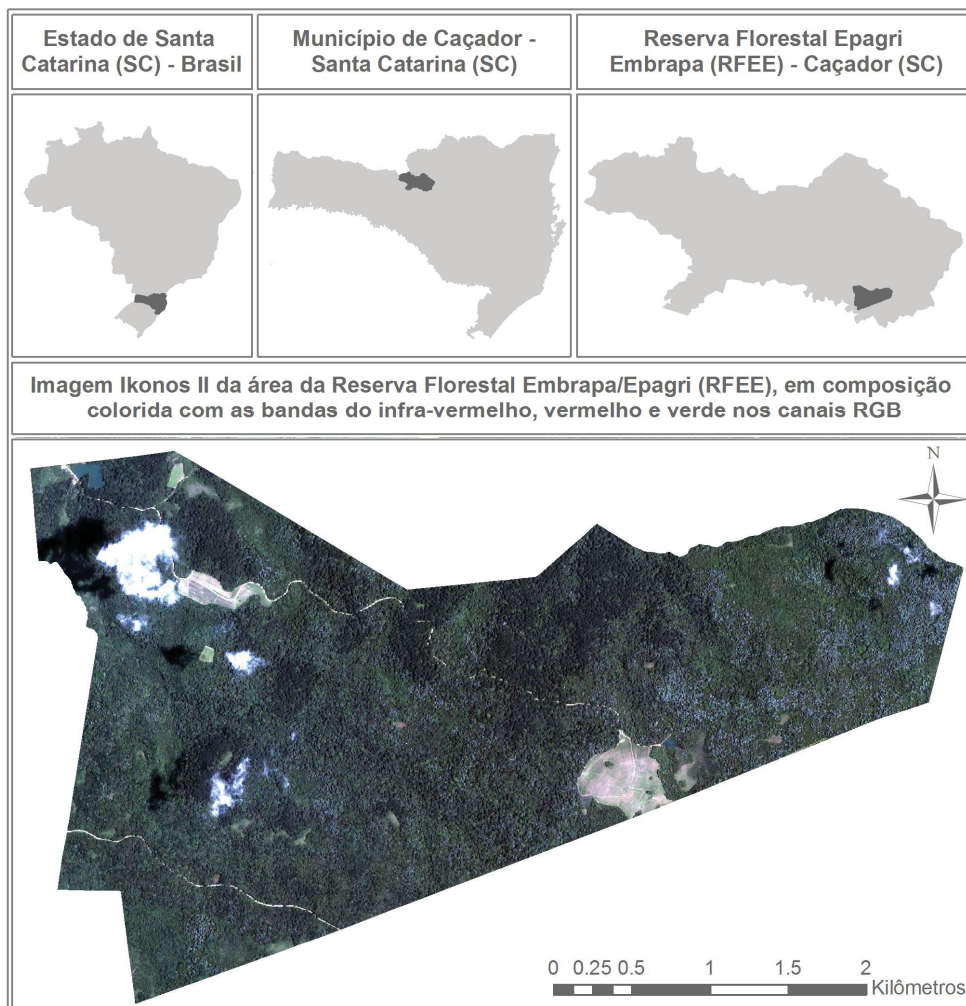


FIGURA 2. LOCALIZAÇÃO DA RESERVA FLORESTAL EMBRAPA/EPAGRI, MUNICÍPIO DE CAÇADOR, ESTADO DE SANTA CATARINA.

A precipitação média anual é de 1613,1mm registrando-se o maior índice pluviométrico no mês de fevereiro, com 174,8mm. A insolação média anual é de 2012,3 horas, apresentando nos meses de dezembro, janeiro e fevereiro o maior número de horas, com uma média de 191,17horas de sol/mês (EMBRAPA, 1994<sup>5</sup> apud DLUGOSZ, 2005).

O relevo caracteriza-se como suave ondulado com altitude variando entre 920 e 1060m s.n.m. A região está assentada sobre a formação geológica do Grupo São

<sup>5</sup> EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. **Parque Florestal do Contestado – Plano Diretor**. Caçador, SC, 1994. 86p.

Bento – sequência rochosa que pode ser enquadrada entre o período jurássico e o cretáceo da Era Mesozóica – apresentando solos originários da decomposição das rochas basálticas, com a predominância de meláfiros que, quando preenchidos por calcita, apresentam solo rico e, quando por sílica, produzem solos pobres em fertilidade (EMBRAPA 1994<sup>6</sup> *apud* DLUGOSZ, 2005).

Um levantamento pedológico semi-detalhado realizado em Setembro de 2003, em escala 1:25000, revelou a presença de nove classes de solos. A classe predominante foi a do tipo “Associação de Cambissolo Háplico Tb Distrófico léptico + Neossolo Litólico Distrófico típico, A moderado” em 466,85ha ou 39,08% do área da RFEE. Em geral, as classes de solo mapeadas apresentam pH ácido e a saturação por bases na sua grande maioria é baixa (inferior a 50%), exceto para as classes Associação de Gleissolo Melânico Tb Eutrófico; Nitossolo Bruno Distrófico típico epi Eutrófico, A moderado; e Nitossolo Bruno Distrófico típico, A proeminente; que apresentam elevados teores de alumínio trocável e matéria orgânica (DLUGOSZ, 2005).

### 3.2. FLORESTA OMBRÓFILA MISTA

Esta floresta, também conhecida como “mata-de-araucária” ou “pinheiral”, é um tipo de vegetação característica do Planalto Meridional, onde ocorria com maior frequência. O termo “Ombrófila” é definido como a formação florestal situada numa região com alta pluviosidade, onde ocorrem chuvas bem distribuídas ao longo do ano; e o termo “Mista” remete ao encontro de duas floras distintas: a Temperada Austro-Brasileira e a Tropical Afro-Brasileira. (IBGE, 1992).

A *Araucaria angustifolia* (Bertol.) Kuntze, conhecida popularmente como pinheiro-brasileiro, araucária ou pinheiro, é uma espécie característica da Floresta Ombrófila Mista. Essa floresta ocorre principalmente nos três estados do sul do Brasil

---

<sup>6</sup> EMPRESA BRASILEIRA DE PESQUISA AGROPECUÁRIA - EMBRAPA. **Parque Florestal do Contestado – Plano Diretor**. Caçador, SC, 1994. 86p.

e originalmente cobria uma área de aproximadamente 20 milhões de ha (REITZ e KLEIN, 1966; KLEIN, 1984). Com grande importância socioeconômica principalmente pela qualidade de sua madeira (REITZ e KLEIN, 1966; RIZZINI, 1978), o pinheiro foi submetido a uma forte exploração predatória, sobretudo, durante a segunda metade do século XX, e sua floresta sofreu acentuado processo de fragmentação (REITZ *et al.*, 1978). Atualmente, os fragmentos florestais da Floresta Ombrófila Mista estão estimadas em 2-4% da área de cobertura original (GUERRA *et al.*, 2002), o que levou a araucária a ser considerada como vulnerável na lista de espécies em extinção (IBAMA, 2008; Port. 37-N 1992) e, mais recentemente, como criticamente em perigo (CR) na lista de espécies ameaçadas de extinção da IUCN (FARJON, 2006).

A Floresta Ombrófila Mista teve significativa importância no histórico de ocupação da região sul, não somente pela extensão territorial que ocupava, mas principalmente pelo valor econômico que representou durante quase um século (KLEIN, 1985). No entanto, a intensidade da exploração madeireira, desmatamentos e queimadas, substituição da vegetação por pastagens, agricultura, reflorestamentos homogêneos com espécies exóticas e a ampliação das zonas urbanas no sul do Brasil, iniciados nos primeiros anos do Século XX, provocaram uma dramática redução da área das florestas originais na região (MEDEIROS *et al.*, 2005).

No Brasil, a área original de Floresta Ombrófila Mista, era de aproximadamente 200.000 km<sup>2</sup>, (MAACK, 1950), ocorrendo com maior intensidade nos Estados do Paraná (40%), Santa Catarina (31%), Rio Grande do Sul (25%), apresentando manchas esparsas no sul de São Paulo (3%), internando-se até o sul de Minas Gerais e Rio de Janeiro (1%) (KLEIN, 1960). Hoje, estima-se que os remanescentes de Floresta Ombrófila Mista, nos estágios primários ou mesmo avançados, não perfazem mais de 0,7% da área original (MMA, 2002), o que a coloca entre as tipologias mais ameaçadas do bioma Mata Atlântica. As indicações mais otimistas registram entre 1 a 2% de áreas originais cobertas pela floresta com araucária nos três Estados do Sul (KOCH e CORRÊA, 2002).

As espécies que compõem a floresta com araucária têm sofrido intensa exploração madeireira e a expansão da agricultura também contribui imensamente para a redução da área coberta com este ecossistema. Apesar de *Araucaria angustifolia* ser uma espécie legalmente protegida e de corte proibido no Brasil, as áreas remanescentes são fragmentadas e espalhadas em sua área de ocorrência original, com poucas grandes populações remanescentes. É crítico o estado de conservação deste tipo florestal e a idade das populações remanescentes é senescente (WREGE *et al.* 2009).

A composição florística deste tipo de vegetação, caracterizado por gêneros primitivos como *Drymis*, *Araucaria* (Australásicos) e *Podocarpus* (Afro-asiático) sugere, em face da altitude e da latitude do Planalto Meridional, uma ocupação recente, a partir de refúgios alto-montanos (IBGE, 1992)

### 3.3. RESERVA FLORESTAL EMBRAPA/EPAGRI

A citação da equipe de pesquisadores responsáveis pelas atividades de monitoramento e manejo da Reserva Florestal Embrapa/Epagri enfatiza a importância ecológica, econômica e cênica de um dos maiores e também um dos últimos remanescentes contínuos com vegetação característica da região fitogeográfica Floresta Ombrófila Mista (ROSOT *et al.*, 2007(a)):

“A reserva representa uma comunidade de Floresta de Araucária onde ainda é possível encontrar, além da fauna característica da tipologia florestal, todos os estratos e espécies de grande valor econômico e ecológico, como a imbuia, canelais, cedros e, de forma a marcar fortemente a paisagem, uma população de grandes pinheiros. O maior exemplar de Cedro (*Cedrella fissilis*) ainda remanescente no Sul do Brasil e algumas das maiores imbuías (*Ocotea porosa*) estão na área da Reserva”. (ROSOT *et al.*, 2007(a), p.9).

Segundo DLUGOSZ (2005), encontram-se presentes algumas das espécies constantes da lista oficial de espécies em extinção do IBAMA (Portaria nº 37-N, de 03.04.1992), objeto de proibição de corte pela Resolução CONAMA 278, de 24.05.2001, ou seja: *Araucaria angustifolia* (pinheiro-do-paraná), *Ocotea porosa* (imbuia) e *Ocotea catharinensis* (canela-preta).

Em levantamento da composição florística realizado por HERRERA (2009), que observou a ocorrência de 71 espécies, 33 famílias e 54 gêneros, constata-se que o padrão florístico que caracteriza a Floresta Ombrófila Mista também é seguido na RFEE. As dez principais espécies da RFEE, segundo o valor de importância ampliado, foram *Cupania vernalis*, *Araucaria angustifolia*, *Ocotea porosa*, *Capsicodendron dinisii*, *Prunus brasiliensis*, *Ocotea pulchella*, *Clethra scabra*, *Matayba elaeagnoides*, *Ocotea puberula* e *Sebastiania commersoniana* (Herrera, 2009). Para o autor, a qualidade da floresta presente na RFEE, quando considerada a forma e a sanidade do fuste conjuntamente, pode ser classificada como deficiente, isto é, de média a má qualidade.

Em outro levantamento, levado a cabo por LINGNER *et al.* (2007), foi observado que as espécies que apresentaram os maiores valores de importância foram: *Araucaria angustifolia*, *Ocotea porosa*, *Cupania vernalis*, *Capsicodendron dinisii*, *Matayba elaeagnoides* e *Cedrela fissilis*, que juntas representam apenas 14,63 % de todas as espécies e participam com 67 % do valor de importância. Percebe-se, portanto, que mesmo ocorrendo grande heterogeneidade na área de estudo, são poucas as famílias, ou até mesmo as espécies, que dominam a floresta (Lingner *et al.*, 2007). Os autores verificaram, analisando a dinâmica do remanescente, que de modo geral, são baixas as taxas de incremento, devido à intensa competição e a pouca disponibilidade de luz nos estratos inferiores. Estes mesmos fatores explicam o porquê das taxas de mortalidade superiores às de ingresso. A análise da estratificação vertical demonstrou que apenas seis espécies apresentam indivíduos em todos os estratos da floresta, sendo esta uma condição favorável a sua manutenção. O mesmo não ocorreu com a araucária, que não apresentou indivíduos

no estrato inferior, o que indica que a sua regeneração está sendo comprometida devido ao avanço das folhosas, sendo este fato comum em florestas em estágio avançado (LINGNER *et al.*, 2007).

Estas características da floresta demonstram não só as consequências das pressões exploratórias a que este remanescente florestal está submetido, mas também a necessidade de estudos voltados à regeneração, recuperação, conservação e uso sustentável deste recurso.

### 3.4. MATERIAIS

Imagens do satélite Ikonos-II, adquiridas em 17 de fevereiro de 2004 às 13 horas e 43 minutos horário de Greenwich (10:43 horário local), foram utilizadas nos testes de segmentação e classificação que resultaram no mapa de uso e cobertura da terra da RFEE. As quatro bandas multi-espectrais e a banda pancromática foram adquiridas individualmente e suas características espectrais e espaciais se encontram na Tabela 2.

TABELA 2. CARACTERÍSTICAS DAS IMAGENS IKONOS-II.

Sensor	Bandas Espectrais	Resolução Espectral (μm)	Resolução Espacial (m)	Resolução Temporal (dias)	Faixa Imageada (km)
Pancromático	Pan	0,45 - 0,90	1	2,9	13 X 13
Multiespectral	Azul	0,45 - 0,52	4	1,5	
	Verde	0,52 - 0,60			
	Vermelho	0,63 - 0,69			
	Infravermelho-próximo	0,76 - 0,90			

FONTE: ENGESAT (2011).

As observações realizadas pelo satélite Ikonos-II tem escala espacial equivalente a medições de campo usualmente realizadas em pesquisas envolvendo mapeamentos ecológicos e da cobertura da terra, podendo ser utilizado para o mapeamento da cobertura vegetal em escala local (GOWARD, 2003; XIE *et al.*, 2008).



As imagens originais passaram pela correção geométrica, realizada com a inclusão de pontos obtidos em campo com a utilização de GPS diferencial, por DLUGOSZ (2005) e colaboradores. No levantamento foi adotado o método relativo estático e alguns critérios foram observados durante a coleta dos dados em campo, como o tempo mínimo de 20 minutos de registro dos sinais dos satélites em cada ponto; captação de sinais de quatro satélites ou mais e  $PDOP \leq 6,0$ .

Os dados coletados foram, então, submetidos a uma correção diferencial relativamente aos dados coletados pela base de rastreamento contínuo, instalada na própria Reserva, com auxílio do *software* de correção diferencial do próprio equipamento. Ao todo, foram adquiridos 25 pontos de controle em campo, que apresentaram precisão horizontal média de 1,33m. A correção geométrica foi realizada adotando-se a equação de transformação “polinômio de primeiro grau” e o método do “vizinho mais próximo” foi adotado para reamostragem dos pixels. Não foi realizada a ortoreificação da imagem neste estudo, pois a metodologia adotada depende da comparação com a imagem-referência, que foi elaborada por meio de interpretação visual e levantamento de campo, por meio da vetorização manual sobre a imagem Ikonos-II georeferenciada. Por ser um mapeamento temático e pela necessidade de comparação com a referência, não foi possível adotar a ortoreificação da imagem. O sistema de projeção *Universal Transverse Mercator* (UTM) e o Datum horizontal *South American Datum of 1969* (SAD-69) foram adotados neste estudo.

As imagens pré-processadas foram segmentadas utilizando-se o aplicativo eCognition® (atualmente denominado Definiens, da empresa homônima) e para a geração dos atributos a partir dos objetos da segmentação, se utilizou o aplicativo de sistema de informações geográficas ArcGIS®, da ESRI, e também o aplicativo de processamento de imagens ENVI®, da ITT *Visual Information Solutions*. Este último foi adotado também para a coleta de amostras de classificação e de verificação para a avaliação da exatidão do mapa final de uso da terra, além de atividades relacionadas à conversão de arquivos.



O aplicativo denominado WEKA, desenvolvido pela Universidade de Waikato, na Nova Zelândia, foi adotado para a indução de árvores de decisão. O *software* é de licença livre, tem distribuição gratuita e está disponível na rede mundial de computadores (WEKA, 2011). O aplicativo é uma coleção de algoritmos de aprendizado para a mineração de dados e permite exportar a árvore de decisão gerada.

As imagens geradas pelos atributos dos polígonos e as imagens originais foram classificadas no *software* MATLAB, através da implementação das árvores de decisão em formato IF-ELSE. A conversão do arquivo texto contendo a árvore de decisão gerado pelo WEKA para o formato IF-ELSE do MATLAB foi utilizada uma rotina implementada em linguagem C++ BUILDER 6.0, desenvolvido e cedido por SANTOS (2010). O autor também desenvolveu a rotina em mesma linguagem para conversão dos valores das amostras exportadas do ENVI para o formato lido pelo WEKA.

Uma planilha eletrônica foi adotada para a manipulação e edição de dados das amostras de treinamento e dos polígonos resultantes das segmentações, bem como para o cálculo das medidas de discrepância e índice de avaliação da segmentação.

Foi adotado como mapa-referência (“verdade de campo”) o mapa de uso e cobertura do solo derivado da interpretação visual da imagem Ikonos-II e vetorização manual dos polígonos, realizado por DLUGOSZ (2005). Para a elaboração do referido mapa, diversas incursões a campo foram realizadas com o objetivo de retificar eventuais erros de interpretação. Nestas ocasiões, avaliações fito-fisionômicas da vegetação foram realizadas pelo autor e pela equipe da Embrapa Florestas com o objetivo de complementar as informações da imagem e classificar as formações florestais.

### 3.5. METODOLOGIA

A metodologia adotada neste trabalho inclui a segmentação das imagens, apresentada na Seção 3.5.1. A primeira etapa para a segmentação é a seleção dos parâmetros, visando o melhor desempenho do algoritmo adotado. Esta etapa foi realizada por meio da avaliação dos resultados da segmentação. Uma avaliação qualitativa foi realizada (Seção 3.5.1.1), adotando a análise visual da imagem segmentada comparativamente à imagem-referência. Por outro lado, uma avaliação quantitativa foi realizada para a otimização da seleção dos parâmetros de segmentação, por meio do cálculo de medidas de discrepância dos polígonos da segmentação relativamente à imagem-referência (Seção 3.5.1.2). A aplicação dos parâmetros selecionados permitiu o cálculo dos atributos espectrais, de forma e de textura dos polígonos obtidos com a segmentação das imagens, conforme apresentado na Seção 3.5.1.3. Em seguida são descritos os algoritmos de árvore de decisão adotados, na Seção 3.5.2 e a sua utilização para a seleção dos atributos dos polígonos, juntamente com o teste estatístico de T (Seção 3.5.3). A metodologia adotada para a classificação das imagens e os procedimentos para a avaliação da qualidade do mapa de uso e cobertura da terra são, por fim, descritos nas Seções 3.5.5 e 3.5.6, respectivamente. Um resumo das etapas que envolvem a metodologia adotada neste trabalho é apresentado, de forma esquemática, através de um fluxograma de atividades, na Figura 3, a seguir.

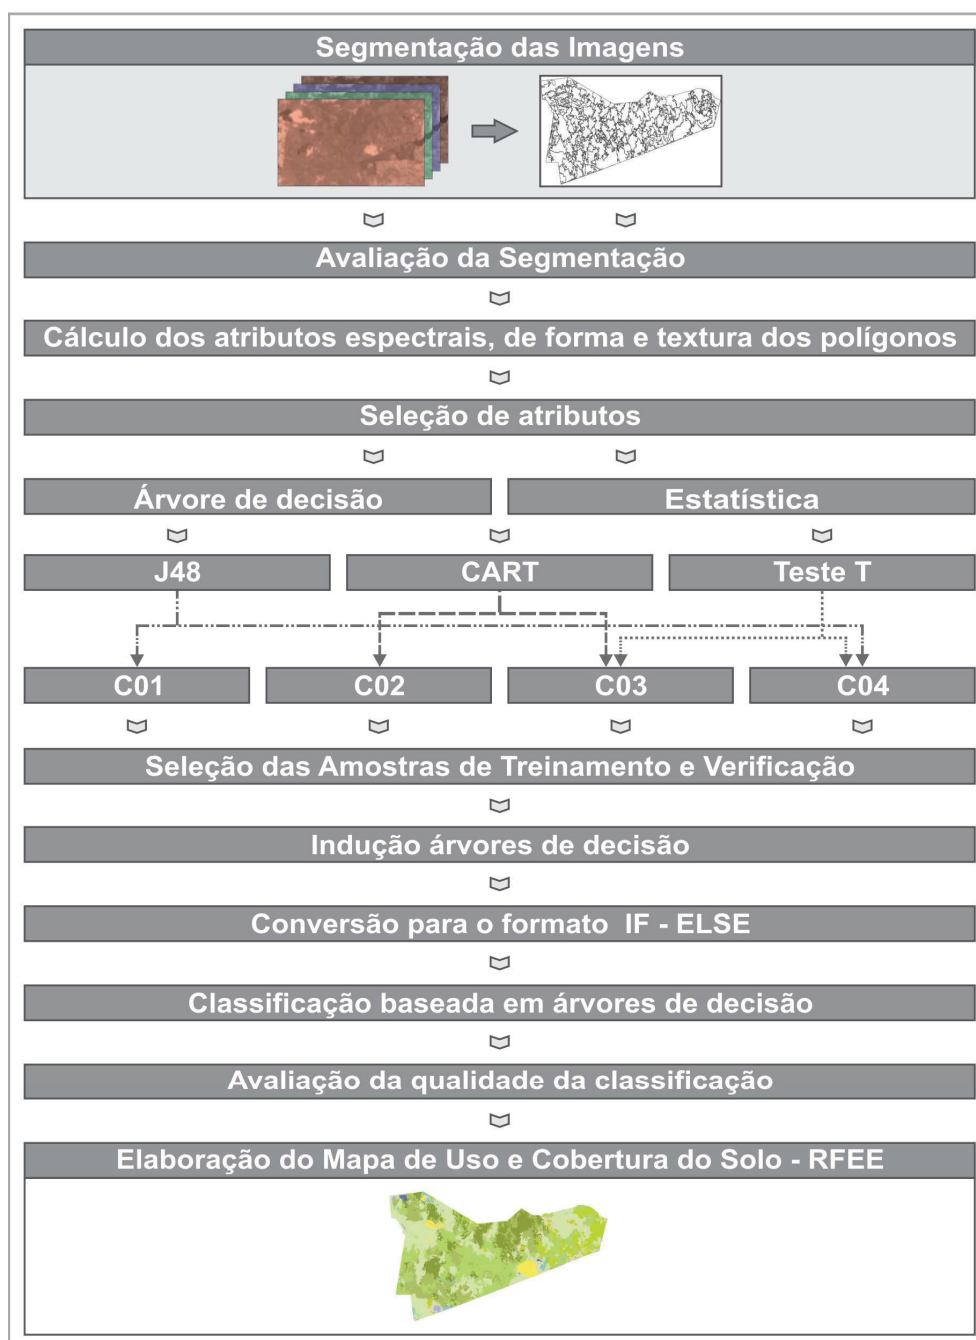


FIGURA 3. FLUXOGRAMA DAS ATIVIDADES QUE COMPÕEM A METODOLOGIA ADOTADA PARA A EXTRAÇÃO DE INFORMAÇÕES A PARTIR DAS IMAGENS IKONOS-II.

### 3.5.1. Segmentação Multi-resolução

A metodologia para a extração das informações a respeito das tipologias da Floresta Ombrófila Mista se inicia a partir da segmentação das imagens Ikonos-II pré-processadas, conforme se pode observar no fluxograma apresentado na Figura 3. Foi

adotado para tanto o algoritmo disponível no *software* eCognition, denominado FNEA (*Fractal Net Evolution Approach*), descrito em detalhes na Seção 2.2.1.1.

Para a segmentação da imagem, podem ser manipulados o parâmetro de escala (PE), o fator de forma (FF) e a relação compacidade/suavidade (CS), que definem o tamanho, a forma e os limites dos objetos resultantes. Estes parâmetros de segmentação devem ser definidos, considerando-se que a qualidade da imagem segmentada e as características dos polígonos resultantes são diretamente dependentes da definição destes parâmetros. A complexidade desta tarefa reside na dificuldade de avaliação dos resultados obtidos e na ausência de uma metodologia apropriada (MÖLLER *et al.*, 2007). Alterações sutis dos parâmetros podem levar a diferenças significativas na definição dos limites dos polígonos, que freqüentemente são visualmente imperceptíveis ao usuário.

Por estas razões, foram adotadas duas formas de avaliação dos resultados produzidos pela segmentação da imagem, permitindo a seleção dos parâmetros de segmentação. A primeira leva em consideração critérios qualitativos e análise visual, realizada de forma comparativa a um mapa de referência, para a seleção dos parâmetros mais apropriados à segmentação das imagens, descrita na Seção 3.5.1.1. A avaliação qualitativa pode ser considerada uma metodologia formal que se aproxima ao método empírico freqüentemente adotado para a seleção dos parâmetros de segmentação realizado por usuários deste algoritmo (CHUBEY *et al.*, 2006; MALLINIS *et al.*, 2008; LUZ *et al.*, 2010; NASCIMENTO, no prelo).

A necessidade de um procedimento que permita avaliar os resultados da segmentação da imagem de forma quantitativa vem sendo apontada por diversos autores (OLIVEIRA, 2003; DLUGOSZ, 2005; KE *et al.*, 2010) e a definição dos parâmetros na ausência de critérios quantitativos é uma dificuldade com a qual qualquer usuário se defronta. Adicionalmente, resultados obtidos por KE *et al.* (2010) indicam que a definição dos parâmetros ótimos efetivamente resultam em classificação de maior qualidade.

A avaliação da segmentação da imagem, que consiste da segunda etapa do fluxograma apresentado na Figura 3 e inclui a avaliação quantitativa e qualitativa, é detalhado no fluxograma apresentado na Figura 4.



FIGURA 4. FLUXOGRAMA DAS ATIVIDADES QUE COMPÕEM A AVALIAÇÃO DA SEGMENTAÇÃO DAS IMAGENS IKONOS-II.

A metodologia de avaliação quantitativa da segmentação adotada foi descrita por OLIVEIRA (2003) e baseia-se no método empírico de discrepâncias que utiliza como princípio o sistema *Relative Ultimate Measurement Accuracy* (RUMA), elaborado por ZHANG e GERBRANDS (1994). Nesta metodologia, descrita em detalhes na Seção 3.5.1.2, as discrepâncias entre a imagem segmentada e a imagem referência compõem o Índice para Avaliação da Segmentação (IAVAS).

#### 3.5.1.1. Avaliação Qualitativa

De forma comparativa ao mapa de uso e cobertura da terra obtido através de interpretação visual procedeu-se a uma avaliação qualitativa dos resultados da

segmentação. Esta avaliação foi realizada sobrepondo-se os polígonos do mapa aos polígonos gerados pelas segmentações realizadas com os pares de valores do parâmetro de escala e do fator de forma.

Foram consideradas nesta avaliação a forma dos polígonos, a área e o número de polígonos, visualmente analisando a similaridade entre o mapa de referência e os polígonos resultantes das segmentações,

Esta avaliação foi realizada levando-se em conta as mesmas características que levariam um intérprete a definir os limites das feições, como a tonalidade e a textura dos níveis de cinza da imagem.

Um dos resultados de segmentação foi selecionado, de acordo com a análise visual e os critérios citados, procedendo-se à classificação da imagem a partir dos atributos gerados para os polígonos resultantes, visando à comparação com a classificação da imagem segmentada com os parâmetros selecionados pelo índice de medidas de discrepância.

Outro objetivo desta avaliação foi o de verificar a possibilidade de seleção dos parâmetros de segmentação utilizando-se apenas a análise visual, realizada por um intérprete treinado e com conhecimentos a respeito do tipo de cobertura de maior interesse, a florestal. Uma pessoa com conhecimentos a respeito da floresta pode, com maior facilidade, delinear as sub-tipologias que ocorrem na Reserva.

#### 3.5.1.2. Avaliação Quantitativa

A metodologia de avaliação da segmentação foi selecionada dada a independência entre as medidas de discrepância e o tipo de algoritmo de segmentação, dependendo somente das imagens a serem segmentadas. O fato de a metodologia fornecer resultados objetivos e quantitativos foi outro dos fatores considerados (OLIVEIRA, 2003). A mesma metodologia foi adotada em trabalho semelhante realizado por DLUGOSZ (2005), na mesma área de estudo e com as mesmas imagens. O autor adotou, no entanto, algumas alterações na metodologia

original de OLIVEIRA (2003). Vale ressaltar que ambos os autores aplicaram a metodologia de avaliação a resultados de segmentações obtidas com o auxílio do algoritmo de crescimento de regiões, implementado no *software* SPRING.

Como imagem de referência se adotou neste trabalho o mapa de uso e cobertura da terra em uso pelos pesquisadores da Embrapa Florestas para a condução de pesquisas na Reserva. O mapa foi obtido a partir da interpretação da imagem realizada por DLUGOSZ (2005), tendo sofrido atualização na legenda e modificações posteriores realizadas a partir de observações em campo.

Diferentemente da metodologia descrita por OLIVEIRA (2003), somente o mapa foi utilizado como referência. O autor se baseia, para o cálculo do índice, em medidas de discrepância calculadas entre a imagem segmentada e duas diferentes versões de referência. Uma delas consiste de um mapa obtido com a coleta de dados em campo com GPS diferencial e a segunda gerada por meio da interpretação visual e vetorização manual de polígonos na tela do computador.

Como o mapa adotado neste trabalho conjuga ambas as formas de obtenção de informações sobre os polígonos de uso e cobertura da terra, e é considerado acurado pelos pesquisadores e técnicos da EMBRAPA FLORESTAS que desenvolvem atividades de pesquisa na área da Reserva, foi considerada desnecessária a execução de um segundo mapa de referência.

Os parâmetros que limitam o crescimento das regiões a cada nova iteração durante o processo de segmentação são o parâmetro de escala (PE) e o critério de homogeneidade. Este segundo é composto, ainda, pelo fator de forma (FF), dado pela relação entre a cor dos pixels e a forma dos polígonos e também pela relação entre a compacidade e a suavidade (CS) da forma dos polígonos. Neste estudo, a relação compacidade/suavidade foi mantida inalterada em 0,5 (CS-0,5<sup>7</sup>), evitando sua influência nos resultados da segmentação. Foram avaliados, portanto, resultados obtidos com a variação do parâmetro de escala e do fator de forma.

---

<sup>7</sup> Os parâmetros de segmentação serão indicados por sua sigla (PE, FF ou CS), seguida do valor adotado.

A exemplo de OLIVEIRA (2003), foi adotada a metodologia de otimização do espaço de combinações, o que facilita a busca pela solução ótima, ou seja, IAVAS mínimo para o teste dos resultados possíveis entre os pares de limiares testados.

Para a avaliação quantitativa, medidas de discrepância que compõem o índice de avaliação da segmentação (IAVAS) foram adotadas: número de polígonos, comprimento total de linhas, variância da área dos polígonos, centro de massa mais próximo e faixa de coincidência. Aspectos relacionados às medidas de discrepância e a metodologia para sua obtenção serão posteriormente descritos, conforme a metodologia proposta por OLIVEIRA (2003).

Para a seleção dos parâmetros ótimos para a segmentação da imagem, foi realizada a busca da solução ótima por meio de um processo de aproximação, adotando-se um espaço de busca finito, para o qual foram amostrados sucessiva e sistematicamente combinações dos parâmetros de segmentação (PE e FF). Este procedimento é descrito a seguir.

#### 3.5.1.2.1. Otimização do espaço de combinações

A aproximação dos valores de limiares testados se deu em quatro fases, onde as medidas de discrepância foram avaliadas e os valores otimizados para cada fase foram tomados como valores centrais da fase seguinte.

Um limite máximo para o parâmetro de escala foi inicialmente estabelecido, já que o aplicativo permite a inserção de quaisquer valores positivos com até quatro dígitos. Mantidos os demais parâmetros constantes e observando-se o tamanho dos polígonos resultantes, se definiu o limite máximo de 550 para o parâmetro de escala. O fator de forma varia entre 0 e 1 com incremento de um décimo. O número de combinações possíveis é de 5500, tornando-se necessária a otimização, que permite a definição do par de valores mais apropriado ao objetivo definido.

O espaço de combinações possíveis foi representado os 30 valores centrais, adotados para a geração das segmentações avaliadas no que se denominou de Fase I, conforme apresenta a Figura 5 (A).



Foram adotados intervalos de incremento em 100 unidades para o parâmetro de escala e em duas unidades para o fator de forma, gerando um conjunto de 30 combinações possíveis de valores centrais das células que compõem o espaço de amostragem das combinações.

O par de valores com melhores resultados na Fase I foi tomado como valor central do espaço de combinações e a partir deste, crescendo-se e subtraindo-se sucessivamente intervalos de 25 unidades para o parâmetro de escala. Os mesmos valores de fator de forma foram avaliados na Fase II, resultando em 30 novas combinações de parâmetros para a segmentação (Figura 5 (B)). A partir dos resultados das Fases I e II, uma nova normalização resultou em IAVAS atualizado.

Na Fase III, o mesmo procedimento foi adotado, tomando-se como valor central o par de parâmetros com melhor resultado, variando-se o parâmetro de escala em cinco unidades e o fator de forma em um décimo de unidade, resultando em dezoito novas segmentações (Figura 5 (C)). Da mesma forma, os resultados da avaliação destas foram adicionados aos anteriores e normalizados. Na Fase IV a variação do parâmetro de escala foi de uma unidade e do fator de forma em um décimo de unidade (Figura 5 (D)). Todos os valores foram normalizados, resultando no índice final de avaliação quantitativa da segmentação pelas medidas de discrepância.

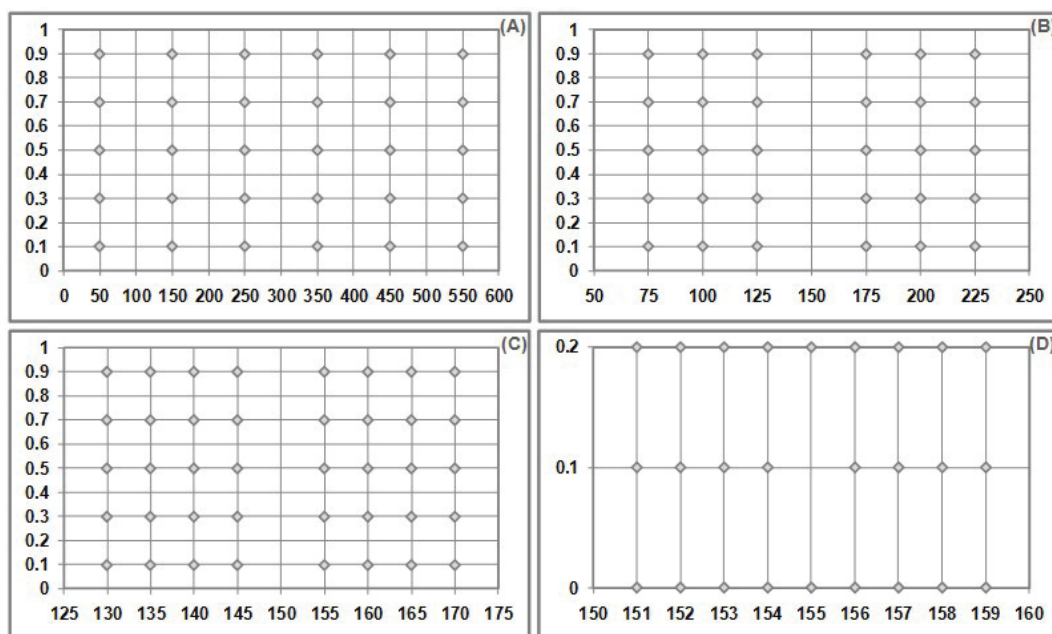


FIGURA 5. REPRESENTAÇÃO DA DIVISÃO DO ESPAÇO DE COMBINAÇÕES ENTRE O PARÂMETRO DE ESCALA E O FATOR DE FORMA E OS PARES DE PARÂMETROS AVALIADOS NAS FASE I; II; III E IV (EM (A); (B); (C) E (D), RESPECTIVAMENTE).

### 3.5.1.2.2. Número de Polígonos

Uma das principais características de uma imagem segmentada com resultados satisfatórios é a quantidade de objetos extraídos pelo algoritmo segmentador. Um grande número de polígonos representa uma segmentação excessiva e a quantidade reduzida de polígonos na cena, por sua vez, uma segmentação insuficiente (OLIVEIRA, 2003). O número de polígonos está diretamente relacionado com os parâmetros de segmentação, que definem o critério de parada no momento de decisão a respeito da inclusão de pixels em um objeto. Esta “decisão” pode levar em consideração características espectrais do pixel a ser incluído ou do arranjo de pixels do objeto pré-existente bem como o tamanho e a forma do objeto em instâncias sucessivas. Critérios de decisão muito restritivos favorecem a criação de um número maior de objetos de área reduzida. Da mesma forma, critérios abrangentes promovem, em geral, polígonos maiores e em maior quantidade (BAATZ e SCHÄPE, 2000; BAATZ *et al.*, 2004).

A discrepância no número de polígonos entre a imagem segmentada e o mapa de referência foi avaliada pela simples contagem de polígonos contidos na área da

Reserva, utilizando-se a ferramenta do *software* ArcGis que retorna o número de polígonos na camada de informação selecionada.

#### 3.5.1.2.3. Variância da área dos polígonos

A inclusão da variância das áreas dos polígonos como medida de discrepância na comparação do mapa de referência e dos resultados de segmentação busca garantir a mesma distribuição estatística da área das feições de interesse (OLIVEIRA, 2003).

A variância das áreas dos polígonos da segmentação (*VAR*) foi calculada com o resultado da área dos polígonos, medida no *software* ArcGIS. Exportando-se a tabela de atributos para o aplicativo de planilha eletrônica, a variância pode ser calculada pela equação (10).

$$VAR = \frac{n \sum_{i=1}^n x_i^2 - (\sum_{i=1}^n x_i)^2}{n(n-1)} \quad (10)$$

onde:

$n$  = número de polígonos;

$x_i$  = área do polígono  $i$

#### 3.5.1.2.4. Comprimento total de linhas

O perímetro dos objetos está intrinsecamente relacionado às suas características, porém é também fortemente influenciado pela forma de mapeamento ou estabelecimento dos limites das feições. Quando a imagem é interpretada e os limites são definidos utilizando-se a representação vetorial, as bordas dos objetos tendem a apresentar um padrão mais retilíneo. Mesmo no caso de fragmentos florestais, quando a projeção das copas das árvores determina linhas curvas ou maior quantidade de nós e vértices para sua representação vetorial, intérpretes humanos freqüentemente desenharam feições mais retilíneas e com menor detalhamento.

Por outro lado, o processo de segmentação por crescimento de regiões ocasiona que mesmo feições retilíneas, como estradas ou plantios agrícolas, sejam

representados por linhas irregulares e de aspecto “dentado”, que variam de acordo com os pixels de borda, divergindo dos limites da feição no terreno.

Esta medida de discrepância foi avaliada ao se comparar a somatória do perímetro de todos os polígonos do mapa referência com a somatória dos perímetros dos polígonos gerados pela segmentação da imagem. Para cada resultado de segmentação exportado para o *software* ArcGIS, foi criada na tabela de atributos uma coluna denominada perímetro, contendo os resultados da mensuração do perímetro de cada polígono.

#### 3.5.1.2.5. Centróide mais próximo

De acordo com OLIVEIRA (2003), o parâmetro que avalia a distância entre os centróides dos polígonos mais próximos busca uma estimativa da coerência espacial entre os polígonos da imagem segmentada e do mapa-referência.

Para a determinação do centróide mais próximo foi calculada a distância euclidiana (equação 11) entre os centróides dos polígonos da segmentação e os polígonos do mapa referência.

$$d_{ij} = \sqrt{(x_i - x'_j)^2 + (y_i - y'_j)^2} \quad (11)$$

onde:

$i$  = número do centro de massa analisado na imagem referência;

$j$  = número do centro de massa analisado na imagem segmentada;

$x_i$  e  $y_i$  = coordenadas x e y do ponto  $i$ ;

$x'_j$  e  $y'_j$  = coordenadas x e y do ponto  $j$ ;

Dada a impossibilidade de identificar polígonos equivalentes em ambos arquivos vetoriais, foram calculadas as distâncias euclidianas para todas as combinações possíveis entre os centros de massa do mapa referência e dos polígonos oriundos de cada segmentação (Figura 6). A média aritmética dos menores valores obtidos representa a discrepância entre os centróides dos polígonos na imagem segmentada e na imagem-referência.

Este procedimento foi realizado criando-se na tabela de atributos de cada arquivo vetorial a coluna contendo as coordenadas UTM do centro de massa de cada polígono. Estes resultados permitiram o cálculo da distância euclidiana, seleção dos menores valores para cada polígono do mapa referência e finalmente, a determinação da média aritmética destes valores.




FIGURA 6. DISTÂNCIA ENTRE OS CENTROS DE MASSA: (A) DISTÂNCIA EUCLIDIANA ENTRE OS CENTROS; (B) MENOR DISTÂNCIA ENTRE OS CENTROS DE MASSA).

FONTE: OLIVEIRA (2003).

#### 3.5.1.2.6. Faixa de coincidência

Em situações em que os polígonos são rotacionados em seu centro de massa, mesmo que possua mesma área, mesmo perímetro e estejam presentes em mesmo número comparativamente ao mapa-referência, não é possível identificar a discrepância na localização dos limites dos objetos (OLIVEIRA, 2003). A faixa de coincidência permite unir a posição e o tamanho dos polígonos com a forma de suas bordas, quantificando os pixels coincidentes entre os arquivos vetoriais. Ainda segundo OLIVEIRA (2003), a avaliação deste parâmetro contribui para a redução de erros relacionados à extração ou identificação da linha divisória entre regiões adjacentes, quando um pixel da linha segmentada é atribuído à região adjacente ou quando o limite na imagem referência for identificado um pixel acima ou um pixel abaixo de sua posição correta.

Para evitar que erros devidos à interpretação visual da imagem, relacionados a limitações que o analista tem em definir o limite dos polígonos, influencie na avaliação dos resultados da segmentação, OLIVEIRA (2003) recomenda a criação de uma faixa de tolerância (FT) de espessura igual à resolução da imagem utilizada, para dentro e para fora dos polígonos do mapa referência. A FT foi criada gerando-se um *buffer* duplo (interno e externo) de 4m, representando a resolução da imagem Ikonos-II (Figura 7).

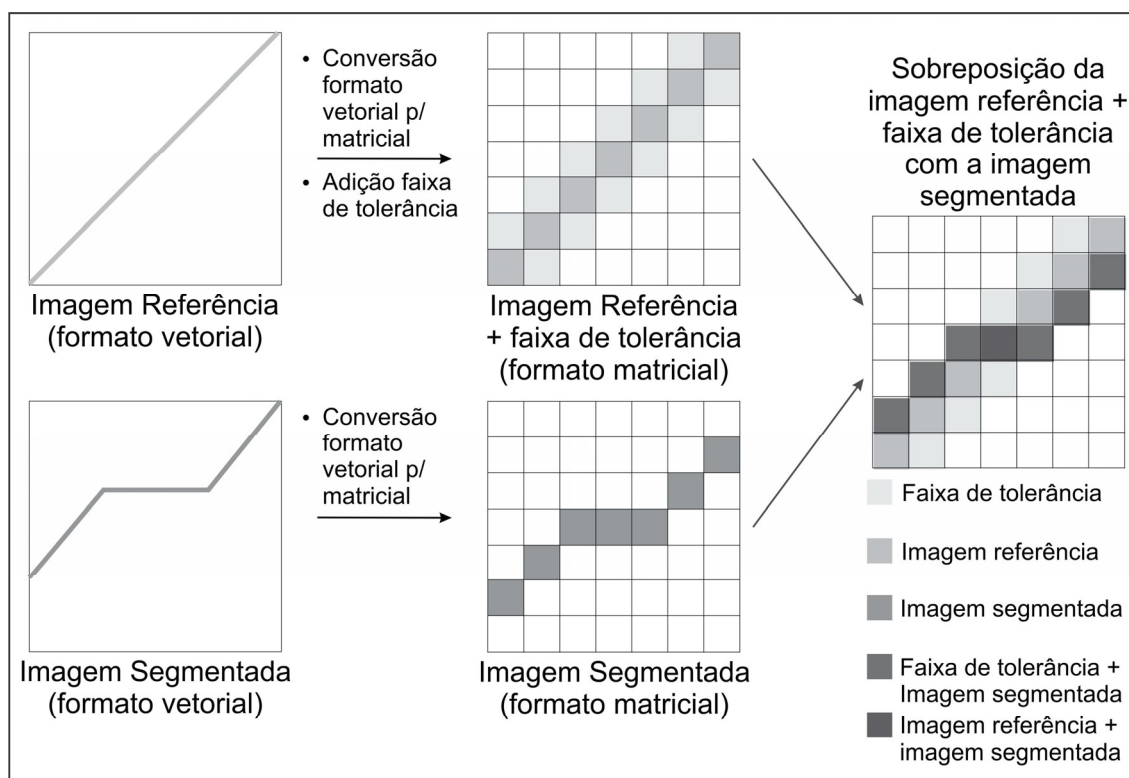


FIGURA 7. DETERMINAÇÃO DA FAIXA DE COINCIDÊNCIA.

FONTE: ADAPATADO DE OLIVEIRA (2003).

Convertendo-se o dado vetorial para matricial e sobrepondo-se o *buffer* e o arquivo matricial de cada segmentação, a interseção das informações permite a geração de um novo arquivo contendo as células presentes em ambos. Com a contagem de células presentes no arquivo, representando os pixels comuns resultantes da intersecção, é possível avaliar a faixa de coincidência.

### 3.5.1.2.7. Cálculo do Índice IAVAS

Dadas as escalas e unidades distintas das cinco medidas de discrepância que compõem o Índice IAVAS torna-se necessária a normalização dos resultados calculados, aplicando-se a cada parâmetro a equação (12), conforme descrito por OLIVEIRA (2003).

$$X_{it} = \frac{X_i - X_{\text{mínimo}}}{S} \quad (12)$$

onde:

$X_i$  = valor observado;

$X_{\text{mínimo}}$  = menor valor do conjunto;

$S$  = desvio padrão

$X_{it}$  = valores transformados;

A seguir apresentam-se as etapas de cálculo do IAVAS conforme descrito por OLIVEIRA (2003).

- 1) Obtenção das diferenças absolutas de cada medida de discrepância entre a imagem de referência e a imagem segmentada;

- a) Número de polígonos:

$$NP = (|NP_R - NP_S|) \quad (13)$$

onde:

$NP_R$  = número de polígonos da imagem referência;

$NP_S$  = número de polígonos da imagem segmentada;

- b) Comprimento total de linhas

$$L = (|L_R - L_S|) \quad (14)$$

onde:

$L_R$  = comprimento total das linhas presentes na imagem referência;

$L_S$  = comprimento total das linhas presentes na imagem segmentada;

- c) Variância das áreas dos polígonos

$$VA = (|VA_R - VA_S|) \quad (15)$$

onde:

$VA_R$  = variância das áreas dos polígonos da imagem referência;

$VA_S$  = variância das áreas dos polígonos da imagem segmentada;

d) Centro de massa mais próximo

$$C = (C_{R-S}) \quad (16)$$

onde:

$C_{R-S}$  = média das menores distâncias entre os centros de massa da imagem de referência para os centros de massa da imagem segmentada;

e) Faixa de coincidência

$$FC = (|NQ_R - NQ_{S \cong (R+FT)}|) \quad (17)$$

onde:

$NQ_R$  = número de quadrículas da imagem de referência;

$NQ_{S \cong (R+FT)}$  = número de quadrículas da imagem segmentada coincidentes com as quadrículas da imagem de referência acrescida da faixa de tolerância (FT);

2) Normalização dos resultados obtidos na etapa 1;

$MVDA$  = menor valor das diferenças absolutas para o parâmetro analisado;

$DPDA$  = desvio padrão das diferenças absolutas para o parâmetro analisado;

3) Soma dos cinco parâmetros normalizados para a constituição do índice IAVAS, conforme a equação (18).

$$IAVAS = \left\{ \left[ \frac{((NP_R - NP_S) - MVDA_{NP})}{DPDA_{NP}} \right] + \left[ \frac{((L_R - L_S) - MVDA_L)}{DPDA_L} \right] + \left[ \frac{((VA_R - VA_S) - MVDA_{VA})}{DPDA_{VA}} \right] + \left[ \frac{((C_{R-S}) - MVDA_C)}{DPDA_C} \right] + \left[ \frac{((NQ_R - NQ_{S \cong (R+FT)}) - MVDA_{FC})}{DPDA_{FC}} \right] \right\} \quad (18)$$



### 3.5.1.3. Cálculo dos atributos dos polígonos

Objetos de imagem delineados através da segmentação são portadores de importantes informações, na forma de métricas derivadas dos objetos das imagens que os caracterizam sob seus aspectos espectrais, de forma, textura e contexto. Muitos são os relatos da contribuição destes atributos para a classificação das imagens (CHUBEY *et al.*, 2006; FORSTER, 2008; WULDER *et al.*, 2009; KE *et al.*, 2010; LUZ *et al.*, no prelo).

Para WULDER (1998), somente a resposta espectral ou o valor do nível de cinza de uma imagem pode ser de uso limitado na estimativa de características florestais, já que o elemento espacial da imagem não é considerado. A textura indica a variação espacial entre valores de pixels vizinhos e sua adição pode fornecer informações significativas sobre parâmetros florestais, representando a distribuição da vegetação. A inclusão da informação a respeito da forma dos objetos tem demonstrado permitir o incremento da exatidão dos resultados da classificação da imagem, aumentando a capacidade de discriminação espacial entre objetos previamente isolados, como os resultantes da segmentação da imagem (WULDER, 1998).

Assim, para o presente trabalho foram calculados, no *software* eCognition, 405 atributos espectrais, da forma e da textura dos polígonos, que compuseram o conjunto inicial de dados de entrada. A partir destes, foi realizada a seleção dos atributos para classificação da imagem. Os atributos calculados são apresentados no Apêndice 13.

### 3.5.2. Árvores de decisão

As etapas de seleção dos atributos dos polígonos da segmentação e também a classificação das imagens foram realizadas com o auxílio de algoritmos de árvores de decisão. Estes algoritmos estão disponíveis no *software* WEKA, anteriormente

mencionado, e serão brevemente descritos a seguir. Maiores detalhes sobre o seu funcionamento podem ser encontrados em QUINLAN, 1986; BREIMAN *et al.*, 1986; MITCHELL, 1997; LIM *et al.*, 2000; ROKACH e MAIMON, 2008; HALL *et al.*, 2009; SHARMA e SAHNI, 2011.

a) *J48*: O algoritmo *J48* é uma versão ligeiramente modificada do algoritmo C4.5, descrito por BREIMAN (1986), implementado no *software* WEKA. C4.5 é um algoritmo que gera uma árvore de decisão para um determinado conjunto de dados de entrada por meio do particionamento recursivo dos dados. As decisões são criadas utilizando uma estratégia “*depth-first*”. O algoritmo considera todos os testes possíveis para o particionamento dos dados e seleciona aquele que fornece o melhor ganho de informação. Para cada atributo discreto, um teste é considerado, com a quantidade de resultados possíveis em igual número ao de valores distintos do atributo. Para cada atributo contínuo, testes binários envolvendo todos os valores distintos do atributo são considerados. Para a obtenção eficiente dos valores de ganho de entropia de todos estes testes binários, o conjunto de dados de treinamento pertencentes ao nó considerado é ordenado pelos valores dos atributos contínuos e o valor de ganho de entropia para cada partição binária é calculado baseando-se em cada valor distinto dos dados ordenados. Para a obtenção eficiente dos valores de entropia são ordenados os dados de treinamento de cada nó e o ganho de entropia é calculado para cada divisão binária dos valores dos atributos. Este processo é repetido para cada atributo e aquele que fornecer o maior ganho de entropia é selecionado. O particionamento dos dados é encerrado quando o número de instâncias a serem particionadas for menor do que determinado limiar. Parte dos dados de entrada é utilizada para o ajuste da árvore através da poda, após a fase de crescimento.

b) *CART* e *SimpleCART*: a sigla *CART* significa “*Classification and Regression Trees*” (do inglês, Árvores de Regressão e Classificação) e o algoritmo que se caracteriza pela construção de árvores binárias (cada nó interno tem exatamente duas saídas) foi desenvolvido por BREIMAN *et al.* (1984). O particionamento de cada nó é selecionado usando-se o critério denominado “*Twoing*” (do inglês, *Twoing Criteria*, que

consiste de uma soma quadrática sobre as diferenças absolutas entre a probabilidade de cada classe pertencer ao nó da direita e a probabilidade de a classe pertencer ao nó da esquerda). A árvore obtida é podada por meio de uma estratégia denominada “*Cost-Complexity Pruning*” (do inglês, poda de custo-complexidade, que significa podar a árvore com base na estimativa do erro e complexidade da árvore, numa espécie de análise da relação custo benefício entre o erro e a complexidade obtida). O algoritmo considera, ainda, o custo de erros de classificação na indução da árvore além de permitir que o usuário forneça uma prévia distribuição de probabilidade. Uma característica importante do *CART* é sua habilidade de gerar árvores de regressão, nas quais números reais são estimados nas folhas terminais, ao invés de classes. Neste caso, o algoritmo busca por opções de particionamento que permitam a minimização do erro quadrático da estimativa. No caso do algoritmo *SimpleCART*, que consiste de uma simplificação do *CART*, foi incluída uma implementação de poda da árvore que leva em consideração a minimização da estratégia de custo-complexidade.

c) *RandomTree*: são algoritmos nos quais as árvores de decisão são construídas randomicamente, com  $k$  atributos randômicos em cada nó, a partir de um conjunto de árvores possíveis. Neste contexto, randomicamente significa que cada árvore do conjunto de árvores possíveis tem iguais chances de amostragem. Outra forma de explicação deste algoritmo é afirmar que a distribuição das árvores é uniforme. As árvores randômicas (do inglês “*RandomTree*”) podem ser geradas de forma eficiente e a combinação de grandes conjuntos de árvores randômicas geralmente conduz a modelos de decisão acurados. Estes modelos têm sido desenvolvidos intensamente no campo de aprendizado de máquina nos últimos anos.

d) *RepTree*: são algoritmos de rápido aprendizado que permitem a construção de árvores de decisão utilizando o ganho de informação como critério de particionamento dos nós, e a poda é realizada por meio da redução do erro de estimativa. Seleciona valores numéricos para os atributos das classes uma única vez e os valores ausentes são tratados utilizando o mesmo método adotado no algoritmo C4.5, de fracionamento de instâncias.

### 3.5.3. Seleção de atributos

A partir dos polígonos gerados pela segmentação da imagem com o par de valores de melhor desempenho segundo avaliação pelo índice IAVAS, atributos espectrais, da forma, da textura dos polígonos e aqueles relacionados à cena foram gerados. No Apêndice 13 se encontra uma listagem contendo os 409 atributos calculados.

Este conjunto de informações foi submetido à seleção dos atributos que mais contribuem à classificação da imagem. A indução por árvore de decisão e também o teste estatístico de T multivariado foram os métodos de seleção de atributos adotados.

A função densidade probabilidade multivariada para d-dimensões da distribuição T de Student é dada pela equação 19.

$$y = f(x, P, V) = \frac{1}{|\Sigma|^{\frac{1}{2}}} \frac{1}{\sqrt{V\pi^d}} \frac{\Gamma\left(\frac{(V+d)}{2}\right)}{\Gamma\left(\frac{V}{2}\right)} \left(1 + \frac{x'P^{-1}x}{V}\right)^{-\frac{(V+d)}{2}} \quad (19)$$

onde:

$x$  é um vetor  $1 \times d$

$P$  é um vetor  $d \times d$  simétrico, matriz definida e positiva;

$V$  é um escalar positivo

ROKACH e MAIMON (2008) consideram que os atributos selecionados para a composição das árvores de decisão podem ser apontados como os mais importantes na classificação da imagem e alguns autores têm feito uso destes algoritmos para a seleção de atributos (SESNE *et al.*, 2008; KE *et al.* 2010, CLARK *et al.*, 2010). Os algoritmos de árvore de decisão utilizados nesta etapa foram o *J48* e o *CART*. Como cada algoritmo gera uma árvore de decisão com diferentes grupos de atributos selecionados, cada algoritmo foi utilizado para determinar os conjuntos de dados a serem utilizados como dados de entrada para a classificação da imagem.

Da mesma forma, os atributos selecionados pelo Teste T compuseram um conjunto de dados de entrada para a classificação da imagem. Desta forma se obtiveram conjuntos de dados compatíveis com a manipulação e a classificação da

imagem, sendo estes os dados de entrada para os demais processamentos referentes à classificação da imagem.

Foram elaborados quatro conjuntos de dados. O primeiro contendo os atributos selecionados pela indução da árvore de decisão gerada pelo algoritmo *J48* (denominado C01), o segundo pela aplicação do algoritmo *CART* para a indução de árvore de decisão (denominado C02), o terceiro formado pelos atributos selecionados pelo método do Teste de T (denominado C03) e o quarto conjugando todos os atributos que compõem os demais conjuntos de dados de entrada (denominado C04).

#### 3.5.4. Classes de Uso e Cobertura do Solo

As classes de uso e cobertura do solo foram definidas de acordo com o estabelecido para o mapa-referência, elaborado por DLUGOSZ (2005), visando a compatibilidade temática e a comparação dos resultados obtidos neste estudo com aquele mapa. Como classes de uso e cobertura do solo que não representam formações florestais, foram denominadas as classes “lago”, “solo exposto”, “estrada”, “agricultura/fruticultura”, e “várzea” (áreas que correspondem ao tipo de vegetação que ocorre em meios com saturação hídrica sazonal a permanente (KOZERA *et al.*, 2009) denominada Vegetação Pioneira de Influência Fluvial (IBGE, 1992).

A definição das classes temáticas referentes às formações florestais considera a ocorrência de espécies indicadoras de estágio sucessional com fisionomia arbustiva a arbórea que compõem o dossel da floresta. As formações identificadas foram referidas por DLUGOSZ (2005) como tipologias, porém o termo foi revisto pelo autor e pela equipe do Laboratório de Monitoramento da Embrapa Florestas, sendo desta forma adotado neste trabalho o termo sub-tipologias (ROSOT *et al.*, 2007(b)). De acordo com ROSOT *et al.* (2007(b)), as sub-tipologias apresentam uma composição particular de espécies, estágios de desenvolvimento e número de estratos, permitindo que tratamentos silviculturais possam ser aplicados de acordo com cada uma delas. LAMPRECHT (1964) citado por ROSOT *et al.* (2007(b)) define

sub-tipologias como o resultado de diferentes níveis de tolerância que as espécies apresentam com relação ao ambiente e sua heterogeneidade. As classes de sub-tipologias da Floresta Ombrófila Mista definidas para este estudo, com base no estudo de DLUGOSZ (2005), são: “predominância de araucária”, “baixa densidade de araucária”, “canelas”, “bracatinga/canela-guaicá”, “vassourão”, “vassourinha”, “vegetação de solos úmidos”, “taquara” e “vegetação de solos úmidos”.

### 3.5.5. Classificação das Imagens

Para a classificação das imagens, diversos algoritmos foram testados. Os conjuntos de atributos selecionados pelos métodos anteriormente citados foram submetidos aos algoritmos de indução de árvores de decisão *J48*, *SimpleCART*, *RandomTree* e *RepTree*.

Os algoritmos *J48*, *CART*, *RandomTree* e *RepTree* foram aplicados a cada um dos quatro conjuntos de dados, totalizando dezesseis classificações para as imagens geradas com os limiares de segmentação selecionados pelo índice IAVAS, realizando-se o mesmo procedimento para as imagens segmentadas com os limiares selecionados empiricamente.

Para a obtenção das classificações, as regras geradas no *software* WEKA pela aplicação de cada um dos algoritmos foram exportadas para o formato de arquivo texto com extensão “*txt*”. Uma rotina foi desenvolvida em linguagem C++ BUILDER 6.0, por SANTOS (2010) para a conversão das regras para o formato IF-ELSE, compatível com o *software* MATLAB®. Neste *software*, os comandos IF-ELSE permitiram a execução da classificação das imagens.

A obtenção das regras se deu com a inclusão dos valores de amostras de treinamento coletadas sobre o mapa de uso e cobertura da terra elaborado por DLUGOSZ (2005), no *software* ENVI. Os valores das amostras foram convertidas para o formato ASCII, posteriormente submetidas ao aplicativo de conversão para o formato ARFF escrito na linguagem C++, cedido por SANTOS (2010).

### 3.5.6. Avaliação da qualidade do mapeamento

Os resultados de classificação obtidos no *software* MATLAB foram exportados para o *software* ENVI e a exatidão dos mapas de uso e cobertura da terra foi avaliada. Para tanto, foram utilizadas amostras independentes daquelas utilizadas para o treinamento dos algoritmos de classificação da imagem.

O arquivo de amostras de verificação foi obtido através da sobreposição de um grid de pontos sobre o mapa referência. A sobreposição e exportação dos pontos do grid contendo o atributo de classe de uso e cobertura da terra foi realizada no *software* ArcGIS. Os pontos importados para o *software* ENVI foram então utilizados para a avaliação da exatidão do mapeamento, através da geração de matrizes de confusão e do cálculo da exatidão e do índice de Kappa. A Figura 8 apresenta o grid contendo os mais de 200.000 pontos utilizados para a verificação da exatidão do mapa de uso e cobertura da terra da RFEE.






FIGURA 8. AMOSTRAS DE VERIFICAÇÃO SOBREPOSTAS À IMAGEM EM COMPOSIÇÃO COLORIDA, COM AS BANDAS DAS REGIÕES DO VERMELHO, VERDE E AZUL NOS CANAIS RGB.



## 4. RESULTADOS E DISCUSSÃO

### 4.1. SEGMENTAÇÃO MULTIRESOLUÇÃO

#### 4.1.1. Avaliação Qualitativa

A avaliação qualitativa é realizada por meio da avaliação visual da qualidade da segmentação, comparativamente à imagem-referência. O objetivo desta avaliação não foi o de adicionar parâmetros qualitativos à avaliação quantitativa e sim o de agir como um intérprete no momento de decisão a respeito do uso de limiares de segmentação. A análise visual foi realizada propositalmente antes da avaliação quantitativa, evitando desta forma a influência do conhecimento dos resultados da avaliação quantitativa e dos limiares capazes de produzir resultados similares à imagem-referência.

Variações sutis nos parâmetros de segmentação frequentemente não são perceptíveis, ou seja, nem sempre diferenças visuais podem ser identificadas. Este aspecto dificulta a determinação de parâmetros de segmentação ótimos, quando se depende unicamente da acuidade visual do analista para identificação destas variações.

A comparação através da sobreposição é facilitada quando a análise visual é realizada em tela de computador, preferencialmente em *software* que permita o acionamento e desacionamento das camadas de informação. Desta forma a identificação das diferenças se dá através da identificação dos limites dos polígonos presentes em apenas uma das camadas de informação, quer seja na imagem-referência ou na imagem segmentada.

Este procedimento de avaliação levou à escolha do parâmetro de escala igual a 325 e do fator de forma igual a 0,1, gerando os polígonos exibidos em um recorte da imagem na Figura 9.




FIGURA 9. COMPARAÇÃO ENTRE RECORTE DA IMAGEM REFERÊNCIA, SOBREPOSTA À COMPOSIÇÃO DA IMAGEM IKONOS-II COM AS BANDAS DO VERMELHO, VERDE E AZUL NOS CANAIS RGB, EM (A); E AS IMAGENS SEGMENTADAS COM PE-300 (B), PE-325(C) E PE-350 (D).

Uma das razões para a seleção destes limiares foi a grande quantidade de polígonos gerados pela segmentação com limiares mais baixos, sobretudo o parâmetro de escala. A imagem-referência contém 429 polígonos e o parâmetro selecionado produziu 466 polígonos.

A imagem segmentada com os parâmetros selecionados pela análise qualitativa foi utilizada na classificação, da mesma forma que a imagem gerada pelos limiares selecionados pela avaliação qualitativa, utilizando as medidas de

discrepância, objetivando a comparação entre os mapas resultantes. O cálculo dos atributos dos polígonos utilizados na classificação da imagem foi realizado, no entanto, com base nos resultados da otimização dos parâmetros de segmentação selecionados na avaliação quantitativa. Desta forma, foi possível padronizar a classificação da imagem, evitando a influência da utilização de atributos diferentes, permitindo a comparação dos resultados.

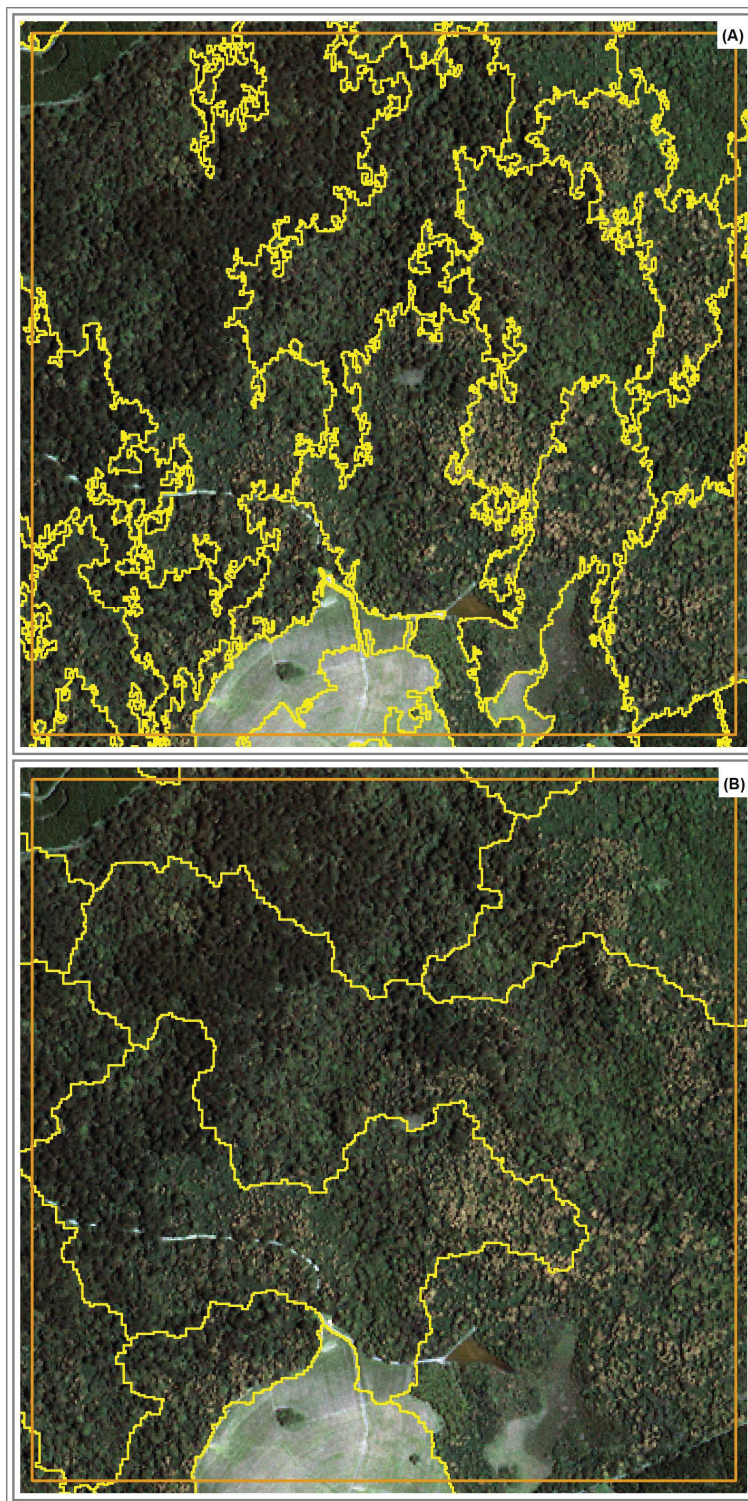
#### 4.1.2. Avaliação Quantitativa

O primeiro passo da avaliação qualitativa da imagem foi a definição do limite máximo para o parâmetro de escala. O fator de forma e a relação compacidade suavidade podem assumir valores entre 0 e 1, tomados como limites superior e inferior do espaço de otimização dos parâmetros de segmentação. A definição destes limites reduz a busca pela solução ótima na otimização dos parâmetros. Em casos de super-segmentação a reconstrução do objeto após a correta classificação é possível, enquanto que nos casos de sub-segmentação a geometria do objeto não pode ser recuperada (MARPU *et al.*, 2010). Para STURM e WEIDNER (2009), a sub-segmentação definitivamente leva à classificação errônea dos polígonos, já que as propriedades inerentes aos mesmos resultam da composição de características de diferentes objetos da superfície terrestre. Com base nestas considerações, uma análise visual da generalização obtida com limites altos de parâmetro de escala permitiu definir o valor máximo adotado.

Foi definido como limite superior o parâmetro de escala 550, observando-se que polígonos de grandes dimensões foram gerados com este valor. Estes polígonos contêm pixels que representam mais de um tipo de cobertura ou classe de uso da terra, indicando que limiares ainda maiores não contribuem para uma melhoria na qualidade da segmentação, sendo desnecessária a sua avaliação (Figura 1). O fator de forma máximo avaliado foi definido em 0,9 e o mínimo em 0,1, para a Fase I. Na



Figura 10 se pode observar que a aplicação do PE-550 resulta na inclusão de mais de um tipo de feição de interesse em um mesmo polígono e os limites dos polígonos



não representam adequadamente as fronteiras dos objetos.

FIGURA 10. SEGMENTAÇÃO OBTIDA COM A APLICAÇÃO DO PARÂMETRO DE ESCALA DE 550 E O FATOR DE FORMA IGUAL A 0,1 (A) E SEGMENTAÇÃO OBTIDA COM A APLICAÇÃO DO PE-550 E DO FF-0,9 (B).

Os resultados dos parâmetros de discrepância calculados entre as imagens segmentadas e a imagem referência, para as 30 combinações de PE e FF, avaliadas na Fase I, constam do Apêndice 1. A partir destes parâmetros de discrepância foi calculado o IAVAS (Apêndice 2), cujos resultados foram sumarizados em função dos parâmetros de segmentação e apresentados no gráfico da Figura 11.




FIGURA 11. SUPERFÍCIE GERADA PELA INTERPOLAÇÃO ESPACIAL DO ÍNDICE DE AVALIAÇÃO DA SEGMENTAÇÃO, CALCULADO DURANTE A FASE I, EM FUNÇÃO DO PARÂMETRO DE ESCALA E DO FATOR DE FORMA.

Como se pode observar na Figura 11, valores baixos para o parâmetro de escala e para o fator de forma resultaram em índices otimizados. Menores valores do IAVAS conduzem a maior similaridade entre a imagem segmentada e a imagem-referência, de forma geral. A região ótima, conforme se pode perceber, se localiza em torno do PE-150 e do FF-0,0 a 0,1. Valores do parâmetro de escala e do fator de forma próximos aos limites máximos do espaço de busca resultam nos mais altos IAVAS calculados. Esta tendência confirma que a seleção do PE-550 e do FF-0,9 como limites superiores foi apropriada.



De fato, o PE-150 e o FF-0,1 resultaram na segmentação que apresentou o menor valor IAVAS nesta etapa (Fase I), com resultado igual a **2,348** (Apêndice 3). A comparação entre os resultados obtidos com a segmentação da imagem aplicando-se o par de valores selecionados pelo índice IAVAS na Fase I e os pares de valores vizinhos no espaço de busca dos parâmetros ótimos são apresentados na Figura 12. É possível, através da comparação proposta, perceber a grande variação no número e nos limites dos polígonos resultantes. A segmentação resultante da aplicação do PE-150 e FF-0,1 contém 1307 polígonos, ao passo que a utilização do PE-50 e FF-0,1 gerou 16.607 polígonos e o PE-250 e FF-0,1 resultou em 466 polígonos (Apêndice 1). Esta grande diferença fica evidente quando as imagens apresentadas na Figura 12 são comparadas.




FIGURA 12. COMPARAÇÃO DO RESULTADO DE SEGMENTAÇÃO COM O PE-150 SELECIONADO NA FASE I (B), COM OS ELEMENTOS VIZINHOS NO ESPAÇO DE BUSCA DA SOLUÇÃO ÓTIMA, PE-50 (A) E PE-250 (C). FF CONSTANTE IGUAL A 0,1.

A combinação de parâmetros selecionados na Fase I (PE-150; FF-0,1) foi tomada como ponto central, a partir do qual elementos vizinhos no espaço de busca da solução otimizada foram definidos, compondo a Fase II do processo de avaliação da segmentação. Os resultados da Fase II permitem verificar que a tendência do comportamento do IAVAS se manteve (Figura 13), resultando no mesmo par de parâmetros selecionados na Fase I. O IAVAS mínimo, calculado pela normalização conjunta dos parâmetros de discrepância das Fases I e II, resultou em **2,785** para PE-150 e FF-0,1 (Apêndice 6).




FIGURA 13. SUPERFÍCIE GERADA PELA PLOTAGEM DO ÍNDICE DE AVALIAÇÃO DA SEGMENTAÇÃO, CALCULADO DURANTE A FASE II, EM FUNÇÃO DO PARÂMETRO DE ESCALA E DO FATOR DE FORMA.

As diferenças nos resultados de segmentação quando a variação do parâmetro de escala é igual a 25 unidades como adotado na Fase II, não são tão evidentes quanto aquelas observadas para a variação de 100 unidades adotada na Fase I. No entanto, a análise da Figura 14 permite identificar visualmente o aumento no número de polígonos e as alterações na definição de seus limites. Enquanto a aplicação do PE-150 e do FF-0,1 gerou 1308 polígonos, a utilização do PE-125 e FF-0,1 gerou 1946 polígonos e do PE175 e FF0,1 resultou na segmentação da imagem em 951 polígonos (Apêndice 4). As diferenças entre o número de polígonos obtidos com os parâmetros ótimos e as segmentações obtidas com parâmetros vizinhos no espaço de busca são bem menores do que as observadas na Fase I, porém ainda expressivas e facilmente perceptíveis em análise visual.




FIGURA 14. COMPARAÇÃO DO RESULTADO DE SEGMENTAÇÃO COM O PE-150 SELECIONADO NA FASE II (B), COM OS ELEMENTOS VIZINHOS NO ESPAÇO DE BUSCA DA SOLUÇÃO ÓTIMA, PE-125 (A) E PE-175 (C). FF CONSTANTE IGUAL A 0,1.

Tomados os valores centrais de PE-150 e FF-0,1 selecionados na Fase II, variações mais sutis (iguais a 5 unidades) foram aplicadas aos parâmetros de segmentação. A análise dos resultados dos IAVAS obtidos, apresentados na Figura 15, evidencia que as variações sutis aplicadas aos parâmetros de segmentação revelam o detalhamento da superfície do espaço de busca da solução ótima, revelando o comportamento do IAVAS. Podem ser percebidas duas regiões de mínimos locais, caracterizadas por depressões que ocorrem por volta do PE-150 e se mantêm constantes ao longo da amplitude de FF (0,0 a 0,9), com exceção do mínimo global, que ocorre para o PE-155 e FF-0,1. Nesta etapa (Fase III), portanto, houve uma mudança na seleção do parâmetro de escala ótimo, anteriormente definido em PE-150. O FF-0,1 anteriormente selecionado foi mantido. Um valor de IAVAS igual a **1,091** (Apêndice 9) foi obtido para o par de parâmetros selecionado (PE-155 e FF-0,1).






FIGURA 15. SUPERFÍCIE GERADA PELA PLOTAGEM DO ÍNDICE DE AVALIAÇÃO DA SEGMENTAÇÃO, CALCULADO DURANTE A FASE III, EM FUNÇÃO DO PARÂMETRO DE ESCALA E DO FATOR DE FORMA.

A dificuldade na identificação visual de diferenças nos resultados de segmentação, quando comparados os polígonos obtidos com PE vizinhos no espaço de busca da solução ótima é visível na Figura 16. O PE-150 resulta em 1307 polígonos enquanto que o de 155 resulta em 1223 e o de 160 em 1133 (Apêndice 7).




FIGURA 16. COMPARAÇÃO DOS RESULTADOS DE SEGMENTAÇÃO COM A REDUÇÃO E AUMENTO DO PARÂMETRO DE ESCALA DE 155 (B), SELECIONADO NA FASE III, PARA 150 (A) E 160 (C). FATOR DE FORMA CONSTANTE IGUAL A 0,1.

Analogamente ao realizado nas etapas anteriores, o par de valores PE-155 e FF-0,1 foi adotado como o valor central do espaço de otimização das segmentações. A partir destes parâmetros de segmentação, variações iguais a 1 foram aplicadas, .

Quando os parâmetros de segmentação foram manipulados com variações menores em torno do par de valores selecionado na Fase IV, a mesma combinação de parâmetros foi selecionada (Pe-155, FF-0,1). A superfície apresentada na Figura 17 revela maior detalhamento obtido com a manipulação dos parâmetros de segmentação em uma unidade. Mínimos locais e o mínimo global estão mais bem definidos, permitindo a confirmação da seleção dos parâmetros de segmentação ótimos. A avaliação dos parâmetros de discrepância na Fase IV resultou no IAVAS igual a **1,203** (Apêndice 12).

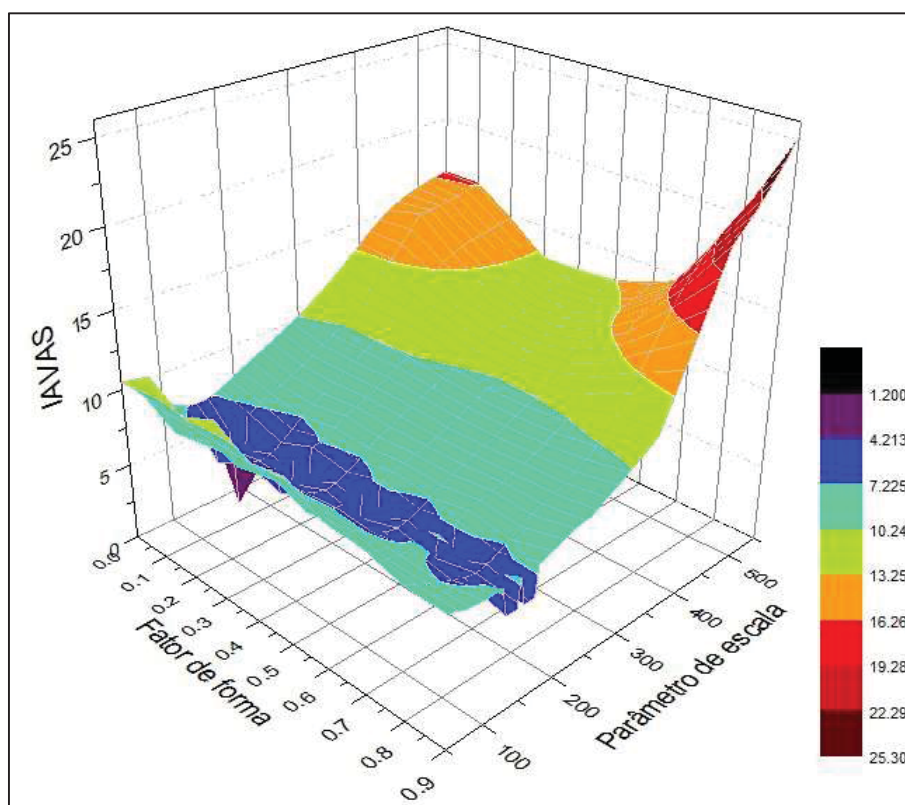


FIGURA 17. SUPERFÍCIE GERADA PELA PLOTAGEM DO ÍNDICE DE AVALIAÇÃO DA SEGMENTAÇÃO, CALCULADO DURANTE A FASE IV, EM FUNÇÃO DO PARÂMETRO DE ESCALA E DO FATOR DE FORMA.

O número de polígonos gerado quando a variação do parâmetro de escala é de apenas uma unidade também varia de forma sutil. A variação entre o número de

polígonos gerados pelo par de parâmetros selecionado (PE-155, FF-0,1) e os elementos mais próximos no espaço de busca é pequena. Foram gerados 1223 polígonos (Apêndice 7) quando PE-155 e FF0,1 foram utilizados, ao passo que PE-154, FF-0,1 resultou em 1239 polígonos e PE-156, FF-0,1 resultou em 1207 polígonos (Apêndice 10). A diferença, como se pode observar, é de 16 unidades em ambos os casos, o que evidencia as sutilezas nas diferenças observadas entre os polígonos resultantes da segmentação das imagens. Variações nos limites dos polígonos são praticamente imperceptíveis em análise visual. Por esta razão não foi incluída na discussão dos resultados a figura comparativa contendo os polígonos gerados. No entanto, o índice de segmentação parece ter sido capaz de quantificar e identificar estas diferenças.

#### 4.2. SELEÇÃO DE ATRIBUTOS E ÁRVORES DE DECISÃO

Dado o elevado número de atributos dos polígonos da segmentação que foram utilizados, fez-se necessária a seleção daqueles mais importantes à discriminação das formações da FOM. Os atributos selecionados compõem os conjuntos de dados de entrada utilizados na classificação da imagem. Além dos 405 atributos dos polígonos fizeram parte da seleção as 4 bandas do satélite Ikonos-II, totalizando 409 camadas de informação, listadas no Apêndice 13.

Os resultados das quatro etapas de seleção de atributos, que deram origem aos conjuntos de dados de entrada C01, C02, C03 e C04 são apresentados na Tabela 3. Foram selecionados 70 atributos e as 4 bandas do satélite, totalizando 74 camadas de informação. Este número representa 18% do conjunto inicial de dados de entrada, igual a 409. Esta seleção tornou viável a utilização dos conjuntos de dados de entrada, em número reduzido, para a classificação das imagens.

Conforme se pode observar pelas informações dispostas na Tabela 3, apenas as bandas originais do satélite Ikonos-II, o atributo Brilho e o atributo Valor máximo dos pixels para a banda do azul foram selecionados pelos três métodos de seleção

de atributos adotados. O conjunto de dados selecionados pelo algoritmo de indução de árvores de decisão *J48* (C01) contém 42 camadas de informação, enquanto que o conjunto de dados selecionados pelo algoritmo de indução de árvores de decisão *CART* (C02) contém 33. O conjunto de dados selecionados pelo teste de T (C03) é composto de 26 camadas de informação. O conjunto C04 é formado pelas 74 camadas de informação selecionadas pelos métodos utilizados.

TABELA 3. CONJUNTOS DE DADOS DE ENTRADA COMPOSTOS PELAS BANDAS DAS IMAGEM IKONOS-II E ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO UTILIZADOS PARA A CLASSIFICAÇÃO DAS IMAGENS.

(continua)

Nº	Bandas / atributos dos polígonos da segmentação	C01	C02	C03	C04
		J48	CART	Teste de T	Seleção Tripla
1	Ikonos-II - Banda do azul				
2	Ikonos-II - Banda do verde				
3	Ikonos-II - Banda do vermelho				
4	Ikonos-II - Banda do infra-vermelho				
5	Brilho				
6	Valor máximo dos pixels (1)*				
7	Valor máximo dos pixels (2)				
8	Valor máximo dos pixels (3)				
9	Valor máximo dos pixels (4)				
10	Diferença Máxima				
13	Média (3)				
14	Média (4)				
15	Diferença média com relação aos vizinhos mais claros (1)				
18	Diferença média com relação aos vizinhos mais claros (4)				
19	Diferença média com relação aos vizinhos mais escuros (1)				
23	Diferença média absoluta com relação aos vizinhos mais claros (1)				
26	Diferença média absoluta com relação aos vizinhos mais claros (4)				
31	Diferença média com relação aos vizinhos (1)				
32	Diferença média com relação aos vizinhos (2)				
34	Diferença média com relação aos vizinhos (4)				
35	Valor mínimo dos pixels (1)				
36	Valor mínimo dos pixels (2)				
37	Valor mínimo dos pixels (3)				

TABELA 3. CONJUNTOS DE DADOS DE ENTRADA COMPOSTOS PELAS BANDAS DAS IMAGEM IKONOS-II E ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO UTILIZADOS PARA A CLASSIFICAÇÃO DAS IMAGENS.

(continuação)

Nº	Bandas / atributos dos polígonos da segmentação	C01	C02	C03	C04
		J48	CART	Teste de T	Seleção Tripla
38	Valor mínimo dos pixels (4)				
39	Razão (1)				
40	Razão (2)				
41	Razão (3)				
42	Razão (4)				
46	Razão com relação à cena (4)				
47	Borda relativa aos vizinhos mais claros (1)				
54	Desvio Padrão (4)				
58	Desvio Padrão com relação aos pixels vizinhos (4)				
62	Assimetria				
64	Comprimento médio das bordas (m)				
66	Área média representada pelos segmentos (m <sup>2</sup> )				
68	Compacidade (polígono)				
69	Compacidade				
71	Grau de ramificação do esqueleto				
73	Distância à borda da imagem (m)				
74	Distância à linha [1]** (m)				
76	Forma elíptica				
77	Comprimento da borda mais longa (polígono (m)				
78	Comprimento do segmento principal (sem ciclos) (m)				
79	Comprimento (m)				
87	Número de ramificações de ordem [1]				
88	Número de objetos internos (polígono)				
95	Desvio padrão da curvatura (somente segmento principal)				
97	Desvio Padrão da área representada pelos segmentos (m <sup>2</sup> )				
100	Coordenada X do centróide (m)				
101	Coordenada X máxima (m)				
102	Coordenada X mínima (m)				
104	Distância X à borda direita da imagem (m)				
105	Coordenada Y do centróide (m)				
108	Distância Y à borda superior da imagem (m)				
112	MCNC 2º Momento Angular 0º (2)				
115	MCNC 2º Momento Angular 135º				



TABELA 3. CONJUNTOS DE DADOS DE ENTRADA COMPOSTOS PELAS BANDAS DAS IMAGEM IKONOS-II E ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO UTILIZADOS PARA A CLASSIFICAÇÃO DAS IMAGENS.

(continuação)

Nº	Bandas / atributos dos polígonos da segmentação	C01	C02	C03	C04
		J48	CART	Teste de T	Seleção Tripla
119	MCNC 2º Momento Angular 135° (4)				
120	MCNC 2º Momento Angular 45°				
136	MCNC Contraste 0° (1)				
170	MCNC Correlação 45°				
181	MCNC Correlação todas as direções (1)				
188	MCNC Dissimilaridade 0° (3)				
235	MCNC Homogeneidade 0°				
238	MCNC Homogeneidade 0° (3)				
253	MCNC Homogeneidade 90° (3)				
254	MCNC Homogeneidade 90° (4)				
264	MCNC Média 0° (4)				
265	MCNC Média 135°				
275	MCNC Média 90°				
293	MCNC Desvio padrão 135° (3)				
310	VDNC 2º Momento Angular 0°				
312	VDNC 2º Momento Angular 0° (2)				
314	VDNC 2º Momento Angular 0° (4)				
319	VDNC 2º Momento Angular 135° (4)				
Número de atributos que compõem os conjuntos de dados de entrada		42	33	26	74

Nota: \* Os números entre parênteses que procedem aos nomes dos atributos referem-se à banda do satélite Ikonos-II utilizada para o cálculo deste atributo.

\*\* Os números entre colchetes que procedem aos nomes dos atributos referem-se a parâmetros envolvidos no cálculo deste atributo.

Um exemplo do formato de árvore de decisão gerado pelo *software* WEKA, utilizado para a indução das árvores de decisão, é apresentado na Figura 18, em (A). Na mesma figura (B) se apresenta um exemplo da implementação da árvore de decisão gerada no *software* WEKA em linguagem do *software* MATLAB, utilizando-se os comandos IF-ELSE para a classificação da imagem. Um exemplo gráfico de parte de uma árvore de decisão gerada pelo *software* WEKA pode ser visualizado na Figura 19. Estes exemplos correspondem a partes da árvore de decisão gerada para o C03 pelo algoritmo J48.

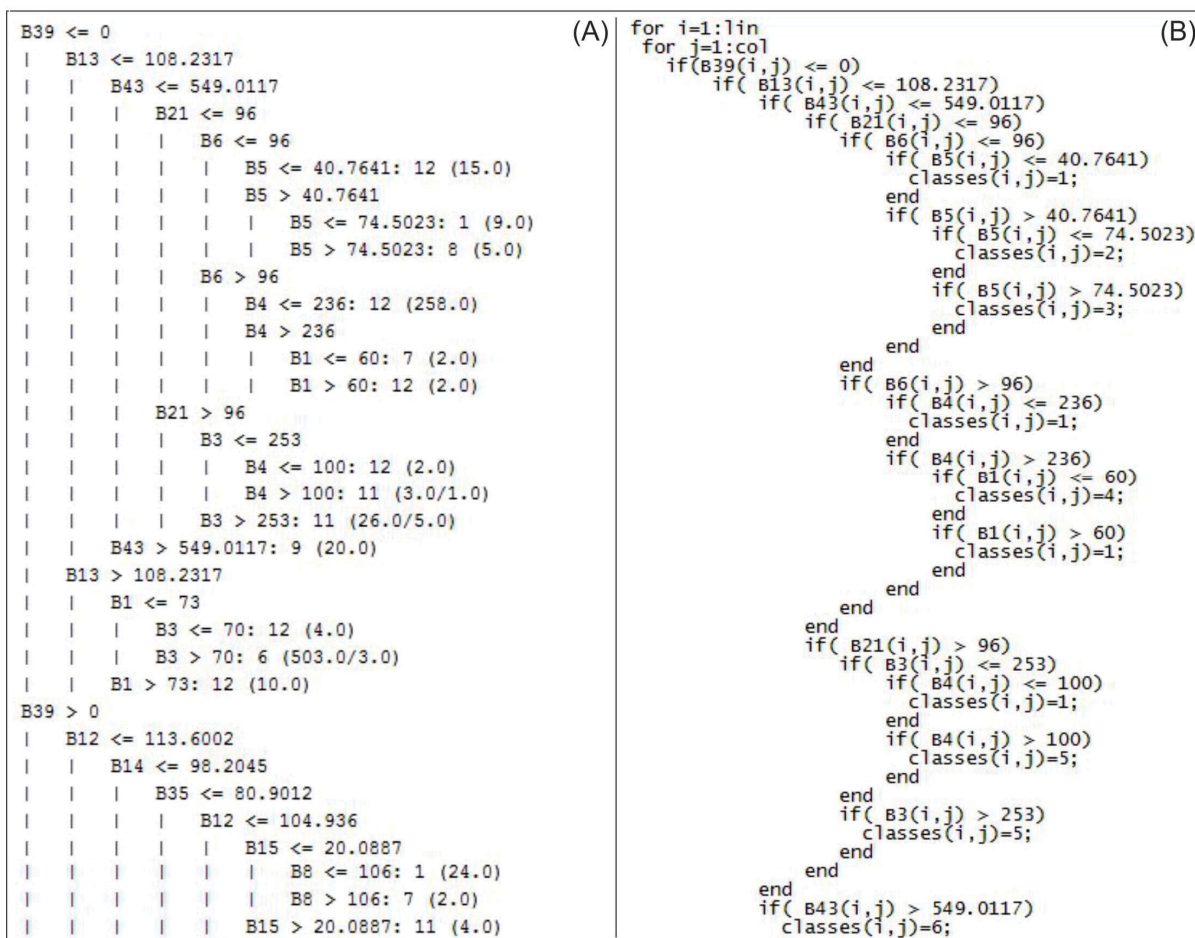


FIGURA 18. EXEMPLO DO FORMATO DE ÁRVORE DE DECISÃO GERADO PELO SOFTWARE WEKA (A) E DO FORMATO IF-ELSE IMPLEMENTADO NO SOFTWARE MATLAB (B).

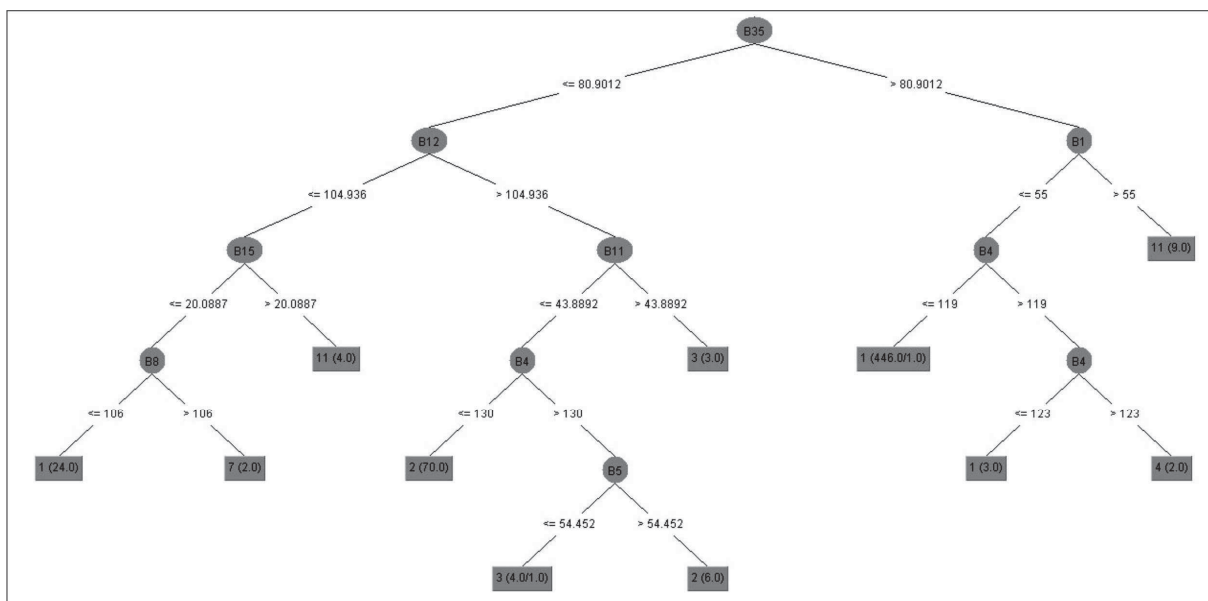


FIGURA 19. EXEMPLO GRÁFICO DE ÁRVORE DE DECISÃO GERADA PELO SOFTWARE WEKA.

#### 4.3. CLASSIFICAÇÃO DAS IMAGENS POR ÁRVORES DE DECISÃO

Utilizando-se os comandos IF-ELSE oriundos da conversão da árvore de decisão gerada pelo *software* WEKA, implementados em linguagem MATLAB, foram classificadas as imagens geradas pelos atributos dos polígonos da segmentação da imagem Ikonos-II. Os resultados obtidos através da avaliação da exatidão da classificação das imagens com os atributos dos polígonos gerados com a aplicação do PE-325 e do FF-0,1 são apresentados na Tabela 4.

TABELA 4. RESULTADOS DA AVALIAÇÃO DA EXATIDÃO DO MAPEAMENTO DO USO E COBERTURA DA TERRA NA ÁREA DA RFEE, GERADO POR MEIO DA CLASSIFICAÇÃO DOS ATRIBUTOS DOS POLÍGONOS OBTIDOS COM A APLICAÇÃO DO PE-325 E FF-0,1.

Algoritmo de árvore de decisão	Conjunto de dados de entrada	Exatidão	Coefficiente de Kappa
<i>SimpleCART</i>	C04	80,16%	0,7741
<i>J48</i>	C02	79,92%	0,771
<i>SimpleCART</i>	C03	79,83%	0,7703
<i>J48</i>	C01	79,74%	0,7692
<i>RepTree</i>	C02	79,56%	0,7674
<i>SimpleCART</i>	C02	78,03%	0,7502
<i>RandomTree</i>	C02	77,14%	0,7402
<i>J48</i>	C04	76,83%	0,7351
<i>J48</i>	C03	73,02%	0,6949
<i>RepTree</i>	C03	72,13%	0,6828
<i>SimpleCART</i>	C01	63,12%	0,5932
<i>RandomTree</i>	C03	62,63%	0,5781
<i>RandomTree</i>	C01	62,15%	0,5851
<i>RepTree</i>	C01	48,98%	0,4461
<i>RandomTree</i>	C04	38,60%	0,3527
<i>RepTree</i>	C04	31,91%	0,2569

De acordo com os valores apresentados, se pode observar grande variabilidade na exatidão obtida, quando diferentes algoritmos de árvore de decisão e conjuntos de dados são adotados. O valor mínimo para a exatidão obtido foi de 31,91%, com a aplicação do algoritmo *RepTree* e o maior conjunto de dados de entrada, C04, formado pelas 74 imagens dos atributos dos polígonos de



segmentação. A maior exatidão obtida atingiu o valor de 80,16% quando o algoritmo *SimpleCART* foi utilizado com o mesmo conjunto de dados de entrada.

Resultado similar foi obtido quando o algoritmo *J48* foi aplicado ao conjunto C02, com 79,92% de exatidão para a classificação da imagem. Da mesma forma, valores de exatidão superiores a 79% foram obtidos para os mapas gerados pela aplicação dos algoritmos *SimpleCART*, *J48* e *RepTree* aos conjuntos de dados de entrada C03, C01 e C02, respectivamente.

O melhor resultado de exatidão do mapeamento do uso e cobertura da terra para a área da RFEE foi obtido quando a imagem foi segmentada com o PE-155 e o FF-0,1; os atributos foram selecionados pela algoritmo *J48* de árvore de decisão e classificados pelo algoritmo *SimpleCART*, resultando na exatidão do mapa de uso e cobertura do solo da RFEE de 83,36% (Tabela 5).

TABELA 5. RESULTADOS DA AVALIAÇÃO DA EXATIDÃO DO MAPEAMENTO DO USO E COBERTURA DA TERRA NA ÁREA DA RFEE, GERADO POR MEIO DA CLASSIFICAÇÃO DOS ATRIBUTOS DOS POLÍGONOS OBTIDOS COM A APLICAÇÃO DO PE-155 E FF-0,1.

Algoritmo de árvore de decisão	Conjunto de dados de entrada	Exatidão	Coefficiente de Kappa
<i>SimpleCART</i>	C01	83,36%	0,8106
<i>RandomTree</i>	C02	83,09%	0,8071
<i>SimpleCART</i>	C02	82,99%	0,8061
<i>J48</i>	C02	82,40%	0,7994
<i>J48</i>	C04	81,43%	0,7881
<i>RepTree</i>	C02	80,92%	0,7828
<i>RepTree</i>	C01	78,57%	0,7556
<i>RandomTree</i>	C04	78,01%	0,7497
<i>RandomTree</i>	C03	78,01%	0,7497
<i>RepTree</i>	C04	77,88%	0,7479
<i>J48</i>	C01	65,57%	0,6146
<i>RepTree</i>	C03	62,28%	0,5445
<i>RandomTree</i>	C01	60,90%	0,564
<i>SimpleCART</i>	C03	31,97%	0,2592
<i>J48</i>	C03	25,06%	0,1792

Resultados próximos a este valor foram obtidos quando os algoritmos *RandomTree* e *SimpleCART* foram aplicados ao conjunto de dados de entrada

selecionados pelo algoritmo *CART* (C02), resultando em 83,09% e 82,99%, respectivamente.

Ao comparar os valores obtidos na classificação usando o produto da segmentação com o PE-325 e o FF-0,1 e a classificação dos atributos gerados com os parâmetros PE-155 e FF-0,1 pode-se perceber que a variabilidade dos resultados obtidos com a segunda é ainda maior. O valor mínimo de exatidão obtido foi de 25,06%, quando o algoritmo *J48* foi utilizado para a classificação do menor dos conjuntos de dados de entrada (C03). Este resultado não se repete para os dados apresentados na Tabela 4.

Os resultados de exatidão e coeficiente de Kappa apresentados sugerem que limiares de segmentação menores, sobretudo a redução do parâmetro de escala, podem produzir mapas de uso e cobertura da terra mais acurados. Este efeito pode ser atribuído ao excesso de generalização gerado pela segmentação quando maiores valores de parâmetro de escala são adotados. Pode-se dizer que é preferível, para a seleção de parâmetros de segmentação e posterior classificação da imagem, a obtenção de uma segmentação excessiva, em termos de número e tamanho de polígonos gerados, do que uma segmentação insuficiente. A segmentação excessiva divide objetos representados na imagem em mais de um polígono, o que pode ser considerado indesejável quando avaliada a segmentação. No caso da posterior classificação da imagem, esta situação é mais favorável do que a oposta, já que os polígonos que compõem um mesmo objeto podem ser corretamente classificados e posteriormente fusionados em um único polígono.

A classificação de melhores resultados apresenta grande confusão entre classes florestais, provavelmente pela reduzida separabilidade espectral entre alguns tipos de cobertura florestal, conforme exposto na Tabela 6. Apesar de a classe 1, denominada “Predominância de Araucária” apresentar 80,84% de acerto, se observa certa confusão (4,84%) com a classe que também apresenta Araucárias em seu dossel, porém com menor densidade (classe 2, “baixa densidade de araucária “), como era de se esperar. A separabilidade destas classes é evidente em campo, dada

a densidade de ocorrência da espécie dominante, porém esta divisão não é tão clara em termos de resposta espectral. Erro pouco menor ocorreu entre esta e a classe “canelas” (classe 3), 4,5%.

A classificação da classe 2 foi a de menor acerto dentre as florestais, e a segunda pior dentre todas as classes. Houve grande confusão (13,57%) entre esta e a classe 3 (“canelas”), com a classe 1, cujo dossel é dominado por Araucárias (7,79%), e também com as classes 4 e 5, formadas pelas espécies vulgarmente conhecidas por Bracatinga (erro de 6,66%) e Taquara (ou taquaral, na linguagem popular) (erro de 5,70%).

A classe das canelas apresentou, reciprocamente, confusão com a classe “baixa densidade de araucária” (7,52%) e também grande confusão com a classe “bracatinga” (10,45%). Apesar da reduzida similaridade espectral, pixels desta classe foram também erroneamente classificados como “taquara” (classe 5).

TABELA 6. MATRIZ DE CONFUSÃO DA CLASSIFICAÇÃO DA IMAGEM PELO ALGORITMO *SIMPLECART*.

Classes	1	2	3	4	5	6	7	8	9	10	11	12	13
1	<b>80,83</b>	7,79	2,73	2,54	0,06	0,00	0,03	0,06	0,02	0,00	1,59	0,00	0,69
2	4,84	<b>54,72</b>	7,52	2,66	0,28	0,00	0,32	0,06	0,08	0,00	0,81	0,00	0,19
3	4,50	13,57	<b>63,08</b>	7,21	0,81	0,00	1,24	0,44	0,62	0,07	0,45	0,00	0,19
4	1,73	6,66	10,45	<b>69,32</b>	3,02	0,00	0,20	1,37	0,18	0,04	1,10	0,00	0,00
5	0,68	5,70	6,37	7,69	<b>93,01</b>	0,00	4,59	0,01	0,04	0,00	0,24	0,00	0,00
6	0,00	0,03	0,00	0,02	0,00	<b>98,59</b>	0,00	0,66	0,00	0,00	0,00	0,00	0,00
7	0,00	0,00	2,85	2,79	2,49	0,00	<b>92,66</b>	0,00	0,01	0,00	0,00	0,00	0,00
8	0,92	2,01	1,73	3,00	0,16	0,00	0,23	<b>95,96</b>	2,19	0,04	1,42	0,00	0,50
9	0,62	0,47	0,45	0,54	0,04	0,00	0,06	1,11	<b>96,06</b>	0,03	1,14	0,43	0,06
10	0,75	0,03	0,35	0,11	0,00	0,00	0,01	0,01	0,17	<b>97,25</b>	1,34	0,00	0,00
11	4,08	6,64	2,65	2,32	0,05	0,00	0,33	0,14	0,62	2,58	<b>90,60</b>	59,15	0,19
12	1,05	2,38	1,83	1,80	0,06	1,41	0,33	0,19	0,02	0,00	1,14	<b>40,43</b>	0,44
13	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,00	0,16	0,00	<b>97,75</b>

Nota: Os números na primeira linha e primeira coluna da tabela referem-se às classes contidas na legenda do Mapa de Uso e Cobertura da terra, conforme a seguinte codificação: 1 - predominância de araucária; 2 - baixa densidade de araucária; 3 - canelas; 4 - bracatinga/canela guaicá; 5 - taquara; 6 - vassourinha; 7 - vassourão; 8 - vegetação de solos úmidos; 9 - várzea; 10 - agricultura/fruticultura; 11 - estrada; 12 - solo exposto; 13 - lago.

A classe 4 (“bracatinga”) foi confundida com a classe “canelas” (classe 3) em 7,21% e também com “taquaras”, com erro de 7,69%. A classe das “taquaras” foi bem

classificada em seus locais corretos de ocorrência na RFEE, já que poucos de seus pixels foram confundidos com outras classes, considerado o acerto de 93,01%.

A alta percentagem de acerto atribuída à classe denominada “vassourinha” (98,59%) provavelmente está relacionada à ocorrência em baixa densidade desta espécie na RFEE, o que implica na utilização das poucas áreas de ocorrência para amostragem, facilitando a classificação. Desta forma, ainda que os pixels utilizados como amostras de treinamento não tenham sido incluídos nas amostras de verificação para avaliação da exatidão, não houve possibilidade de uma avaliação espacialmente dependente para este tipo de cobertura florestal. Esta classe tem ocorrência em 0,07% da área da RFEE.

A classe 7, “vassourão”, foi a classe florestal de maior acerto, com 92,66%. Esta alta taxa de acerto para um conjunto de classes de alta dificuldade de classificação, dada a confusão espectral entre classes que muitas vezes são compostas pelas mesmas espécies em maior ou menor densidade, pode ser explicada. Esta espécie é também denominada Vassourão Branco, e apresenta dossel acinzentado, dadas as características das plantas. Este pode ser considerado o dossel florestal de maior separabilidade dentre aqueles que compõem a legenda da cobertura florestal da RFEE.

As classes 8, 9 e 10 apresentaram valores elevados de acerto, respectivamente 95,96%, 96,06% e 97,25%. A classe 8 representa a vegetação que ocorre sobre solos úmidos, denominada “vegetação de várzea”, e ocorre em 1,27% da área da RFEE. Os solos encharcados e não cobertos por vegetação são aqui denominados de “várzeas”, e ocorrem em percentagem ainda menor na área, 0,92%. No caso da agricultura, acredita-se que o acerto para esta classe esteja relacionado não somente à área de ocorrência (2,24%), que é um pouco maior do que as classes citadas, mas também à facilidade de separação entre áreas agrícolas e florestas.

A classe “estradas” foi corretamente classificada em 90,60% de sua área de ocorrência. Diferentemente do inicialmente esperado, observou-se confusão entre as estradas e as classes 1 e 2 (4,08% e 6,64%). Estes percentuais de erros não deveriam

ocorrer com esta intensidade, dadas as grandes diferenças espectrais entre a classe “estradas” e as classes “predominância de araucária” e “araucária em baixa densidade”. Uma explicação para este efeito pode ser a proximidade com a rede viária, que facilitaria a mistura espectral entre a estrada e parte do dossel ou de algumas copas da floresta adjacente, além da possibilidade de coleta equivocada de pixels de ambas as classes.

A classe “solo exposto”, apesar de ser encontrada em apenas 0,04% da RFEE, apresenta valor de acerto na classificação dos pixels em apenas 40,43%, sendo observada confusão de 59,15% com a classe de estradas, que supera o acerto na classificação deste tipo de cobertura. Este é um resultado abaixo do esperado, apesar de existir uma expectativa de dificuldade na separabilidade espectral destes alvos. As estradas na RFEE não são pavimentadas, portanto a cobertura é praticamente a mesma para ambas as classes, diferenciando-se apenas o uso antrópico a que se destinam.

Os corpos d’água (“lago”) encontrados na RFEE foram corretamente classificados em 97,75% dos casos, devendo-se considerar que estes resultados são relativos dada a reduzida cobertura deste tipo de superfície, igual a 0,25% da área.

O mapa de uso e cobertura da terra gerado pela classificação da imagem que apresentou melhor resultado de exatidão global, elaborado por meio da classificação pelo algoritmo *SimpleCART* do conjunto de dados de entrada C01 (cujos atributos foram selecionados pelo algoritmos J48) é apresentado na Figura 20. Os resultados da classificação digital podem ser considerados satisfatórios, por estarem próximos ao valor de 85% indicado como satisfatório por Anderson *et al.* (1976) citado por DLUGOSZ (2005). DLUGOSZ (2005) realizou trabalho de pesquisa com a segmentação e a classificação da imagem Ikonos-II na mesma área de estudo. O autor utilizou o algoritmo de segmentação do *software* SPRING e realizou classificação supervisionada pelo método *Bhattacharya*, obtendo uma exatidão global de 51,73%.

Além disso, se considera que a metodologia adotada permitiu a obtenção de um mapa do uso e cobertura da terra de forma em tempo menor do que aquele que seria obtido por meio da vetorização manual dos polígonos. Adicionalmente, em particular para o caso da RFEE, onde informações de campo estão disponíveis e são frequentemente atualizadas, acredita-se que novas cenas futuramente adquiridas poderiam ser processadas adotando-se esta metodologia, o que reduziria o tempo e o custo de elaboração de um mapa atualizado.

Em áreas onde haja indisponibilidade de uma imagem-referência de qualidade comparável à adotada neste estudo (neste caso, o próprio mapa de uso e cobertura da terra), podem ser manualmente vetorizados recortes de áreas significativas das classes temáticas do mapeamento, representativas das características da área de interesse, a exemplo de OLIVEIRA (2003); CARLEER *et al.* (2004); KIM e MADDEN (2006); MÖLLER *et al.* (2007).

Vale ressaltar a facilidade de utilização desta metodologia, que apesar de incluir com algumas etapas, especialmente no caso da indisponibilidade da imagem-referência, não é complexa, já que a extração do conhecimento para a classificação da imagem se dá de forma automática. No caso de sistemas de interpretação de imagens baseados em conhecimento (a exemplo do eCognition e InterIMAGE), é intensa e muito importante a interação entre o usuário e todas as etapas do processamento da imagem. Conforme apontado por RIBEIRO, 2010: “o funcionamento destes sistemas se baseia na introdução do conhecimento do analista a respeito da cena, sendo uma formalização da visão de um determinado indivíduo sobre uma imagem específica. O resultado da classificação passa a ser um reflexo do conhecimento e da capacidade de compreensão do analista”. Esta dependência pode trazer muitas vantagens, permitindo que o conhecimento do analista se torne explícito e seja traduzido na qualidade do mapa de uso e cobertura da terra elaborado. No entanto, pode também consistir de complexos procedimentos realizados somente por um especialista treinado e, em alguns casos, a complexidade dos dados de entrada e da resposta espectral dos alvos de interesse dificultam a obtenção de resultados

satisfatórios. Além disso, pode ser demorado o processo que garante que as estruturas semânticas e de representação do conhecimento sejam formalizadas, conforme observado em experiências anteriores do autor (LUZ, 2010).

A adoção da metodologia para a discriminação de formações da Floresta Ombrófila Mista em outras áreas de ocorrência dependerá, teoricamente, da seleção de novos parâmetros de segmentação ótimos e também dos demais procedimentos que seriam adotados na classificação de imagens tradicional, tais como a amostragem das classes de uso e cobertura do solo. Isto porque uma nova árvore de decisão deve ser gerada para cada imagem, sobretudo se imagens de outros satélites, que não o Ikonos-II, forem utilizadas. Assim sendo, acredita-se que a metodologia tem o potencial de aplicação para a discriminação destas e de outras formações vegetais, com a mesma facilidade de uso dos algoritmos tradicionais, podendo ser utilizada inclusive por usuários com conhecimentos não tão avançados de sensoriamento remoto.



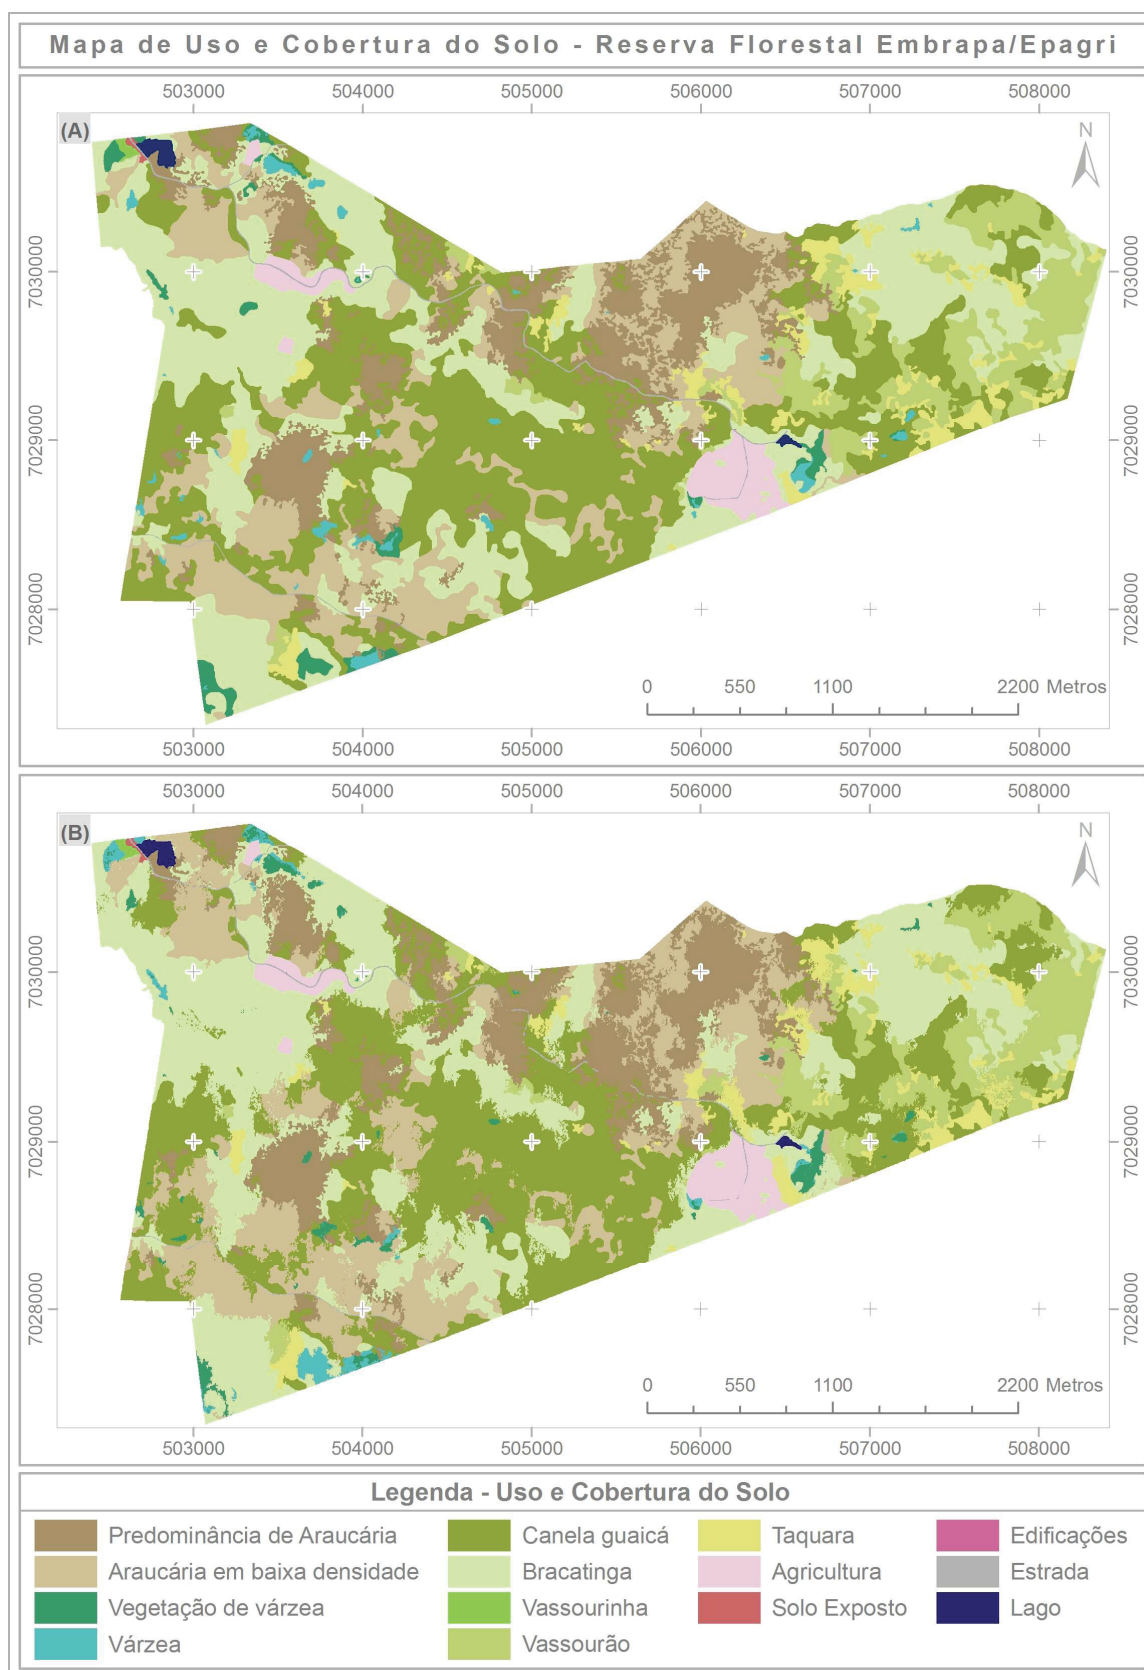


FIGURA 20. MAPAS DE USO E COBERTURA DA TERRA DA RFEE, OBTIDOS POR INTERPRETAÇÃO VISUAL (A) E CLASSIFICAÇÃO DA IMAGEM IKONOS-II (B). SISTEMA DE PROJEÇÃO: UNIVERSAL TRANSVERSE MERCATOR. DATUM: SAD-69.

FONTE: EM (A), DLUGOSZ (2005). EM (B), O AUTOR.



## 5. CONCLUSÕES

A classificação das imagens com a utilização dos algoritmos de árvores de decisão se demonstrou uma metodologia robusta e de fácil utilização, além de permitir que o usuário compreenda a forma de extração das informações das imagens através dos ramos e nós que dividem e atribuem os pixels às classes. Os resultados podem ser considerados satisfatórios, sobretudo se levadas em conta as características das classes de cobertura florestal de interesse, que possuem alta similaridade espectral.

A importância do fragmento de vegetação estudado com relação ao tipo florestal que representa impulsiona esforços de pesquisa na área da Reserva Florestal Embrapa/Epagri. Atividades de manejo e conservação deste fragmento e deste ecossistema são planejadas e apoiadas por informações extraídas a partir de dados de sensores remotos.

Ao mesmo tempo em que informações acuradas são prementes, dificuldades na sua obtenção ainda não foram sobrepujadas. Apesar da disponibilidade de imagens de alta resolução espacial como as utilizadas nesta pesquisa, restrições inerentes aos sistemas sensores ainda se apresentam, tais como a resolução espectral. Técnicas tradicionais aplicadas à discriminação de tipologias complexas como as florestais, que apresentam diferenças sutis em sua resposta espectral, ainda afetam a capacidade de identificação de padrões.

Adicionalmente, os processos de sucessão natural e também as ações antrópicas historicamente sofridas pela vegetação nativa acabam por caracterizar diferentes classes ou tipologias florestais. A sucessão natural favorece o crescimento e domínio do dossel por determinadas espécies que, em um momento seguinte, podem compor o sub-dossel, porém ainda contribuindo com a resposta espectral da feição. A densidade de espécies, como no caso das classes de Predominância de Araucária e de Araucária em Baixa Densidade, contribui para a ocorrência de diferenças sutis na resposta espectral e na dificuldade de identificação destes padrões.

Colocados estes fatores, podem ser considerados satisfatórios os resultados atingidos por esta pesquisa, ainda que aquém do desejado pelos pesquisadores e técnicos envolvidos com o estudo, monitoramento e a conservação da Floresta Ombrófila Mista.

De forma específica se desejam apontar a seguir aspectos considerados relevantes e que levam a conclusões atingidas com este trabalho de pesquisa:

- a) a segmentação multi-resolução se mostrou adequada à generalização da imagem e obtenção de objetos significativos comparativamente ao mapa-referência adotado;
- b) a metodologia de avaliação quantitativa da segmentação permitiu a seleção, através dos resultados do índice IAVAS, do parâmetro espacial de 155 e do fator de forma de 0,1;
- c) a comparação entre os resultados de segmentação gerados pela aplicação dos parâmetros selecionados pelos métodos quantitativo e qualitativo evidenciam a necessidade da avaliação quantitativa;
- d) as árvores de decisão e o teste-T demonstraram-se apropriadas, no contexto deste trabalho, à seleção dos atributos, permitindo a formação de conjuntos de dados de entrada significativos à classificação da imagem e de menor dimensionalidade, permitindo a redução dos 409 atributos dos polígonos para 6 a 18%;
- e) a classificação das imagens com a utilização dos algoritmos de árvores de decisão demonstrou ser capaz de produzir resultados aproximadamente 30% mais acurados do que resultados anteriores, para a mesma área;
- f) a classificação da imagem usando o conjunto de atributos selecionados pelo algoritmo *J48*, gerados para os polígonos obtidos com a segmentação da imagem com os parâmetros selecionados pela avaliação quantitativa, atingiu exatidão de 83,36%, usando-se o algoritmo *SimpleCART*;

- g) todos os algoritmos de árvore de decisão produziram resultados superiores a 80% quando aplicados à imagem segmentada com os parâmetros selecionados pela avaliação quantitativa;
- h) A integração de diferentes procedimentos metodológicos preexistentes, como a segmentação multi-resolução, a avaliação quantitativa dos resultados da segmentação e a classificação baseada em objetos por meio de algoritmos de árvore de decisão, permitiu uma otimização qualitativa da extração de padrões da Floresta Ombrófila Mista, quando utilizadas imagens multi-espectrais.

## **6. RECOMENDAÇÕES FINAIS**

A metodologia de avaliação da segmentação permitiu a seleção de limiares adequados ao propósito desta pesquisa, fornecendo subsídios indispensáveis à tomada de decisão em um processo comumente realizado de forma empírica. A comparação entre os polígonos resultantes da segmentação realizada com parâmetros selecionados pela avaliação qualitativa com aqueles obtidos pela avaliação quantitativa demonstrou a premência da inserção do sistema de avaliação da segmentação de imagens no processo de extração de informações. Alterações sutis no parâmetro de escala podem gerar diferenças quase imperceptíveis, em análise visual, nos resultados da segmentação. No entanto, estas diferenças podem ser significativas quanto à similaridade com o mapa de referência ou mesmo podem se traduzir em mapas de uso e cobertura da terra de melhor qualidade. Posteriores investigações podem estar relacionadas à classificação de imagens submetidas à segmentação com diferentes parâmetros, visando à avaliação do impacto que alterações sutis destes parâmetros ocasionam na qualidade do mapa final. Outro interessante tópico de pesquisa nesta mesma linha seria o estudo de métodos de

avaliação da segmentação *a priori*, que não dependem de um mapa de referência (RADOUX e DEFOURNY, 2008).

A abordagem de imagens orientada a objetos tem sido adotada com sucesso em muitos estudos, especialmente no processamento de imagens de alta resolução espacial. A ampla adoção desta abordagem tem esbarrado no custo dos aplicativos comercialmente disponíveis, sobretudo em instituições governamentais, onde a diretriz é a utilização de aplicativos gratuitos ou de código aberto. Um sistema para a interpretação de imagens baseada em conhecimento, denominado InterIMAGE, desenvolvido em consonância com a filosofia código aberto, tem sido objeto de pesquisas e certamente constitui interessante tema de investigações, com potencial de aplicação no monitoramento da vegetação da RFEE. O aplicativo se demonstrou capaz de gerar resultados de classificação comparáveis aos produzidos por aplicativos comerciais, o que o torna bastante atrativo, sobretudo por ser um produto nacional e livre (de disponibilização gratuita e código aberto) (COSTA *et al.*, 2008; 2010; Cintra *et al.*, 2010). Além disso, a implementação de rotinas multi-temporais, ferramentas de depuração de modelos de interpretação e novos operadores de processamento de imagens previstos para os próximos anos, devem tornar o sistema ainda mais atrativo.

A complexidade de tipologias florestais tropicais, onde diferentes classes estão, em muitas situações, relacionadas a uma mesma composição de espécies que ocorrem em diferentes densidades, ocasiona diferenças sutis na resposta espectral, dificultando a separabilidade entre as classes. Por esta razão, a aplicação desta metodologia a imagens hiperespectrais, com maior potencial quanto à discriminação de padrões, certamente consiste em intrigante e vasto campo para a pesquisa da resposta espectral e discriminação de padrões da Floresta Ombrófila Mista.

## REFERÊNCIAS

- ACCO, M. **Modelagem de dados do satélite Ikonos-II para estimativa de micronutrientes na Floresta Ombrófila Mista Montana**. 68p. Dissertação (Mestrado em Ciências Florestais) - Programa de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba, 2004. Disponível em: <<http://dspace.c3sl.ufpr.br:8080/dspace/handle/1884/1666>> Acesso em: 16/03/2011.
- AMITT, Y. **2D Object detection and recognition: models, algorithms and networks**. Cambridge, MA: MIT, 306 p., 2002.
- ASCENÇO, S. M. A. **Análise ambiental de fragmentos florestais em assentamentos rurais**. 158p. Dissertação (Mestrado em Geografia). Setor de Ciências de Terra, Universidade Federal do Paraná, Curitiba, 2003.
- BAATZ, M.; HEYNEN, M.; HOFMANN, P.; LINGENFELDER, I.; MIMLER, M.; SCHÄPE, A.; WEBER, M.; WILLHAUCK, G. **eCognition User Guide**. München: Definiens AG, 2000.
- BAATZ, M.; SCHÄPE, A. Object-Oriented and Multi-Scale Image Analysis in Semantic Networks. In: PROCEEDINGS OF THE 2ND INTERNATIONAL SYMPOSIUM ON OPERATIONALIZATION OF REMOTE SENSING, 2., 1999, Enschede. **Proceedings...** Enschede: International Institute for Geo-Information Science and Earth Observation – ITC, 1999.
- BECKER, F. G.; IRGANG, G. V.I; HASENACK, H.; VILELLA, F. S.; VERANI, N. F. Land cover and conservation state of a region in the Southern limit of the Atlantic Forest (river Maquiné basin, Rio Grande do Sul, Brazil). **Brazilian Journal of Biology**, São Carlos (SP), v.64 n.3b. 2004.
- BENDER, E. A.; WILLIAMSON, S. G. **Mathematics for Algorithm and Systems Analysis**. 256p. 2005.
- BERRY, J.K.; BUCKLEY, D.J.; MCGARIGAL, K. **Integrating landscape structure programs with Arc Info**. 1998. Disponível em: <<http://www.esri.com/library/userconf/proc98>> Acesso em: 20 /08/2001
- BLASCHKE , T.; STROBL, J. What's wrong with pixels? Some recent developments interfacing remote sensing and GIS. **GeoBIT/GIS** v. 6, p. 12 - 17, 2001.
- BLASCHKE , T.; LANG, S.; LORUP, E.; STROBL, J.; ZEIL, P.: Object-oriented image processing in an integrated GIS/remote sensing environment and perspectives for environmental applications. In: CREMERS, A. & GREVE, K. (Eds.): **Umweltinformation für Planung, Politik und Öffentlichkeit / Environmental Information for Planning, Politics and the Public**, Marburg: Metropolis - Verlag, v. 2: p. 555-570, 2000.

Blaschke, T. Object based image analysis for remote sensing. **ISPRS Journal of Photogrammetry and Remote Sensing**, v. 65, p. 2–16, 2010.

BLASCHKE, T.; LANG, S.; MÖELLER, M. Object-based analysis of remote sensing data for landscape monitoring: recent developments. In: SIMPÓSIO BRASILEIRO DE SENSORIAMENTO REMOTO, 12. (SBSR), 2005, Goiânia. **Anais...** São José dos Campos: INPE, 2005. p. 2879-2886. Disponível em: <<http://urlib.net/ltid.inpe.br/sbsr/2004/11.19.16.55>>. Acesso em: 15/10/2010.

BLUM, R. S.; LIU, Z. (Eds.). **Multi-sensor image fusion and its applications**, special series on signal processing and communications, Boca Raton: CRC, 505 p., 2005.

BOURG, N.A.; MC SHEA, W.J.; GILL, D. E. Putting a *CART* before the search: successful habitat prediction for a rare forest herb. **Ecology**, v.86, n.10, p.2793-2804. 2005.

BOYD, D.S.; DANSON, F.M. Satellite remote sensing of forest resources: three decades of research development. **Progress in Physical Geography**, v.29, n.1, p.1-26. 2005.

BREIMAN, L.; FRIEDMAN, J. H.; OLSHEN, R. A.; STONE, C. J. **Classification and regression trees**. Boca Raton: Chapman & Hall, p. 386, 1984.

CANAVESI, V. **Estimativa de macronutrientes em Floresta Ombrófila Mista Montana utilizando dados de campo e dados obtidos a partir de imagens do satélite Ikonos-II**. 116f. Dissertação (Mestrado em Ciências Florestais, Manejo Florestal) - Programa de Pós-Graduação em Engenharia Florestal, Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba. 2004.

CANAVESI, V., KIRCHNER, F. Quantificação de macronutrientes em floresta ombrófila mista montana utilizando dados de campo e dados obtidos a partir de imagens do satélite Ikonos-II. **Floresta**, v.35, n.3 2005.

CARLEER, A.P.; DEBEIR, O.; WOLFF, E. Comparison of very high spatial resolution satellite image segmentations. In: CONFERENCE ON IMAGE PROCESSING AND SIGNAL PROCESSING FOR REMOTE SENSING, 9., 2004, Barcelona; SPIE INTERNATIONAL SYMPOSIUM ON REMOTE SENSING, 2004, Barcelona. **Proceedings...** Washington: SPIE - International Society for Optics and Photonics 2004, vol. 5238, p.532–542.

CARVALHO, M. M. X. de; NODARI, E. S. As origens da indústria madeireira e do desmatamento da floresta de araucária no Médio Vale do Iguaçu (1884-1920). **Cadernos do CEOM**, n. 29., p.63-81. 2008.

CHUBEY, M.S.; FRANKLIN, S.E.; WULDER, M.A. Object-based analysis of Ikonos-2 imagery for extraction of forest inventory parameters. **Journal of the American Society for Photogrammetry and Remote Sensing** v.72, n.4, p: 383-394. 2006.

CINTRA, D. P. ; NOVACK, T. ; REGO, L. F. G. ; COSTA, G. A. O. P. ; FEITOSA, R. Q. . PIMAR Project - Monitoring the atlantic rainforest remnants and the urban growth of the Rio de Janeiro city (Brazil) through remote sensing. In: GEOBIA 2010, 2010, Ghent, Belgium. Proceedings of the GEOBIA 2010, 2010.

CLARK, M.L.; AIDE, T.M.; GRAU, H.R.; RINER, G. A scalable approach to mapping annual land cover at 250 m using MODIS time series data: A case study in the Dry Chaco ecoregion of South America. **Remote Sensing of Environment**, v.114, n.11, p.2816-2832. 2010.

COOPS, N.C.; WULDER, M.A.; IWANICKA, D. An environmental domain classification of Canada using earth observation data for biodiversity assessment. **Ecological Informatics**, v.4, n.1, p.8-22. 2009.

COSTA, G. A. O. P.; FEITOSA, R. Q.; CAZES, T. B.; FEIJÓ, B. Genetic adaptation of segmentation parameters. In: BLASCHKE, T.; LANG, S.; HAY, G. F. (Ed.) **Object-Based Image Analysis - Spatial Concepts for Knowledge-Driven Remote Sensing Applications**, Berlin: Springer, 2008. p. 679-695.

COSTA, G. A. O. P.; FEITOSA, R. Q.; FONSECA, L. M. G.; OLIVEIRA, D. A. B.; FERREIRA, R. S.; CASTEJON, E. F. Knowledge-based interpretation of remote sensing data with the interimage system: major characteristics and recent developments. In: GEOGRAPHIC OBJECT-BASED IMAGE ANALYSIS CONFERENCE (GEOBIA 2010), 3., 2010, Gent. **Proceedings...** 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/395RRUP>>. Acesso em: 19/02/2011.

COSTA, G.A.O.P. ; PINHO, C.M.D. ; FEITOSA, R.Q. ; ALMEIDA, C.M.; KUX, H.J.H. ; FONSECA, L.M.G.; OLIVEIRA, D.A.B. INTERIMAGE: Uma Plataforma Cognitiva Open Source para a Interpretação Automática de Imagens Digitais. **Revista Brasileira de Cartografia**, v. 60, p. 331-337, 2008.

DISPERATI, A.A. Aplicação de Métodos Computadorizados em Mapeamento Florestal. **Floresta**, v.12, n.2, p.13 -22. 1981.

DLUGOSZ, F. L. **Classificação orientada a regiões na discriminação de tipologias da Floresta Ombrófila Mista usando imagens orbitais Ikonos**. 135p. Dissertação (Mestrado em Ciências Florestais), Departamento de Ciências Florestais, Universidade Federal do Paraná. 2005.

ENGESAT. Disponível em: <<http://www.engesat.com.br>> Acesso em: 23/08/2010.

FORMAN, R. T. T. **Land Mosaics - the ecology of landscapes and regions**. Cambridge: Cambridge University Press, 632 p., 1995.

FORSTER, M.; FRICK, A.; WALENTOWSKI, H.; KLEINSCHMIT, B. Approaches to utilising QuickBird data for the monitoring of NATURA 2000 habitats. **Community Ecology**, v.9, n.2, p.155-168. 2008.



FRANKLIN, J.; WOODCOCK, C. E. Multiscale vegetation data for the mountains of Southern California: spatial and categorical resolution. In: QUATTROCHI, D. A.; GOODCHILD, M. F. (Eds.). **Scale in remote sensing and GIS**. Boca Raton: CRC, p. 141 - 168, 406 p., 1997.

FRANKLIN, S. E. **Remote Sensing for Sustainable Forest Management**. Boca Raton: Lewis Publishers. 2001.

FRIEDL, M. A.; BRODLEY, C. E. Decision Tree Classification of Land Cover from Remotely Sensed Data. **Remote Sensing of Environment**, New York, v. 61, n. 3, p. 399 - 409, 1997.

GEHRKE, J.; RAMAKRISHNAN, R.; GANTI, V. Rainforest - a framework for fast decision tree construction of large datasets. In: PROCEEDINGS OF THE 24TH INTERNATIONAL CONFERENCE ON VERY LARGE DATABASES, 24., 1998, New York, **Proceedings...** New York : Morgan Kaufmann, p. 416-427. 1998.

GOEBEL, M.; GRUENWALD, L. A survey of data mining *software* tools. **SIGKDD Explorations Newsletter**, New York, v. 1, n.1, p. 20 - 33, 1999.

GONZALEZ, R.C.; WOODS, R. E.; EDDINS, S. L. **Digital image processing using MATLAB**. New Jersey: Prentice Hall, 609p, 2004.

GOODALE, M. A. Visual Processing Streams. In: WILSON, R. A.; KEIL, F. C. (Eds.). **The MIT encyclopedia of the cognitive sciences**. Cambridge, MA: MIT, p., 1999.

Goodchild, M. F. (1990). Spatial information science. In Proceedings, Fourth International Symposium on Spatial Data Handling, pp. 3–12, Zurich, Switzerland.

Goodchild, M. F. (1992). Geographical information science. *International Journal of Geographical Information Systems*, 6(1):31–45.

GOWARD, S. Empirical comparison of LANDSAT 7 and Ikonos-II multispectral measurements for selected Earth Observation System (EOS) validation sites. **Remote Sensing of Environment**, v.88, n.1-2, p.80-99. 2003

HALL, M.; FRANK, E.; HOLMES, G.; PFAHRINGER, B.; REUTEMANN, P. WITTEN, I. H. The WEKA Data Mining *Software*: An Update. **SIGKDD Explorations**, vol.11, n.1, 2009.

HAN, J.; KAMBER, M. **Data mining**: concepts and techniques. 2. ed. San Francisco: Morgan Kaufmann, 770 p., 2006.

HAND, D. **Construction and assessment of classification rules**. CHICHESTER: J. Wiley & Sons, 214 p., 1997.



Hansen, M. C.; DeFries, R. S.; Townshend, J. R. G.; Sohlberg, R.; Dimiceli, C.; Carroll, M. Towards an operational MODIS continuous field of percent tree cover algorithm: examples using AVHRR and MODIS data. **Remote Sensing of Environment**, v. 83, n. 1-2, p. 303 – 319. 2002.

HAY, G.J., CASTILLA, G. M.; WULDER, M.A.; RUIZ, J.R. An automated object-based approach for the multiscale image segmentation of forest scenes. **International Journal of Applied Earth Observation and Geoinformation**, v. 7, p. 339 – 359, 2005.

HAY, G.J., CASTILLA, G. Object-based image analysis: strengths, weaknesses, opportunities and threats (SWOT). In: Lang, S.; BLASCHKE, T.; Schöpfer, E. (Eds.). PROCEEDINGS OF THE 1st INTERNATIONAL CONFERENCE ON OBJECT-BASED IMAGE ANALYSIS, 1., 2006, Salzburg. **Proceedings...** Salzburg: International Society for Photogrammetry and Remote Sensing - ISPRS, 2006.

HELMER, E.H.; LEFSKY, M.A.; ROBERTS, D.A. Biomass accumulation rates of Amazonian secondary forest and biomass of old-growth forests from LANDSAT time series and the Geoscience Laser Altimeter System. **Journal of Applied Remote Sensing**. v.3. 2009.

HELMER, E.H.; RUZYCKI, T.S.; WUNDERLE, J.M.; VOGESSER, S.; RUEFENACHT, B.; KWIT, C.; BRANDEIS, T.J.; EWERT, D.N. Mapping tropical dry forest height, foliage height profiles and disturbance type and age with a time series of cloud-cleared LANDSAT and ALI image mosaics to characterize avian habitat. **Remote Sensing of Environment** v.114, n.11, p.2457-2473. 2010.

HERRERA, H., ROSOT, N., ROSOT, M., OLIVEIRA, Y.. Análise florística e fitossociológica do componente arbóreo da Floresta Ombrófila Mista presente na Reserva Florestal Embrapa/Epagri, Caçador, Sc – Brasil. **FLORESTA**, 39, 2009.

HOFMANN, P.; REINHARDT, W. The extraction of GIS features from high resolution imagery using advanced methods based on additional contextual information – first experiences. In: XIX ISPRS CONGRESS, 19., 2000, Amsterdam. **Proceedings...** Amsterdam: International Society for Photogrammetry and Remote Sensing - ISPRS, v. 33, p. 51-58, 2000.

IBAMA. Instituto Brasileiro do Meio Ambiente e dos Recursos Naturais Renováveis. **Portaria nº 37-N, de 03 de abril de 1992**. Lista Oficial de Espécies da Flora Brasileira Ameaçada de Extinção. 2p. 1992.

IBGE. **Manual técnico da vegetação brasileira**. Rio de Janeiro: Departamento de Recursos Naturais e Estudos Ambientais, (Manuais Técnicos em Geociências, n.1). 92p. 1992.

IEEE - INSTITUTE OF ELECTRICAL AND ELECTRONICS ENGINEERS. **IEEE standard glossary of image processing and pattern recognition terminology**. New York: IEEE, IEEE Standard 610, 4. 1990.

JONES, M. T. **Artificial Intelligence: A Systems Approach**. Burlington: Jones & Bartlett Publishers. 2008.

JU, J.; GOPAL, S.; KOLACZYK, E. D. On the choice of spatial and categorical scale in remote sensing land cover characterization. **Remote Sensing of Environment**, v.96, n.1, p.62 - 77, 2005.

KASABOV, N. K. **Foundations of neural networks, fuzzy systems, and knowledge engineering**. Cambridge: MIT Press. 1996.

KE, Y.; QUACKENBUSH, L. J.; IM, J. Synergistic use of QuickBird multispectral imagery and LIDAR data for object-based forest species classification. **Remote Sensing of Environment**, v.114, n.6, p.1141-1154. 2010.

KERR, J.T.; OSTROVSKY, M. From space to species: ecological applications for remote sensing. **Trends in Ecology & Evolution**. v.18, n.6, p.299-305. 2003.

KIM, M.; MADDEN, M. Determination of optimal scale parameter for alliance-level forest classification of multispectral Ikonos-II images. In: International Conference on Object-based Image Analysis, 1., 2006, Salzburg. **Proceedings...** Salzburg: Salzburg University, 2006.

KIM, M.; MADDEN, M.; Warner, T. A. Forest type mapping using object-specific texture measures from multispectral Ikonos-II imagery: segmentation quality and image classification issues. **Photogrammetric Engineering and Remote Sensing**, v. 75, n. 7, p. 819–829. 2009.

KING, D.J. Airborne remote sensing in forestry: sensors, analysis, and applications. **The Forestry Chronicle**, v.76, n.6, p.859-876. 2000.

KLEIN RM. Aspectos dinâmicos da vegetação do sul do Brasil. **Sellowia**, v.36, p. 5 - 54. 1984.

KLEIN, R. M. O aspecto dinâmico do pinheiro-brasileiro. **Sellowia**. v.12, p.17 - 48. 1960.

KOCH, Z. CORRÊA, M.C. **Araucária: a Floresta do Brasil Meridional**. Olhar Brasileiro, Curitiba, 2002.

KOEHLER, A. B. **Modelagem biométrica e morfometria em povoamentos jovens de Araucaria angustifolia (Bert.) KTZE., em Tijucas do Sul, Estado do Paraná**. 128 f. Tese (Doutorado em Engenharia Florestal) - Setor de Ciências Agrárias, Universidade Federal do Paraná, Curitiba. 2009.

KONAR, A. **Artificial intelligence and soft computing**: Behavioral and cognitive modeling of the human brain. New York: CRC, 786 p. 2000.

KOVACSOVA, P.; ANTALOVA, M. Precision forestry - Definition and technologies. **Sumarski List**, v.134, n.11-12, p.603-611. 2010.

KOZERA, C.; KUNIYOSHI, Y. S.; GALVÃO, F.; CURCIO, G. R. Composição florística de uma Formação Pioneira com Influência Fluvial em Balsa Nova, PR, Brasil. **Floresta**, v. 39, n. 2, p. 309-322. 2009.

KURASZ, G. **Sistema de Informações Geográficas aplicado ao Zoneamento Ambiental da Reserva Florestal Embrapa/Epagri, Caçador-SC**. Dissertação (Mestrado em Ciências Florestais). Universidade Federal do Paraná-UFPR, Curitiba-PR. 137 p. 2005.

LIM, T.; LOH, W.; SHIH, Y. A Comparison of Prediction Accuracy, Complexity, and Training Time of Thirty-Three Old and New Classification Algorithms. **Machine Learning**, v.40 n.3, p.203-228, 2000.

LIM, T.-S.; LOH, W.-Y.; SHIH, Y.-S. **An empirical comparison of decision trees and other classification methods**. Madison: Department of Statistics, University of Wisconsin. Relatório, n. 979, 11 p. 1997. Disponível em: <<http://www.cs.cornell.edu/~alexn/papers/comparison.tr.pdf>> Acesso em: 28/06/2008.

LINGNER, D. V.; OLIVEIRA, Y. M. M. D.; ROSOT, N. C.; DLUGOSZ, F. L. Caracterização da estrutura e da dinâmica de um remanescente de Floresta de Araucária no Planalto Catarinense. **Pesquisa Florestal Brasileira**, Colombo, n. 55, p. 55-66. 2007.

LUZ, J. da. **Imagens Alos para o mapeamento da vegetação arbórea e outros usos do solo em área de Floresta Ombrófila Mista**. 121p. Dissertação (Mestrado em Ciências Florestais), Departamento de Ciências Florestais, Universidade Federal do Paraná. 2005.

LUZ, N. B. da; SANTOS, D. J. DOS; MENDONÇA, A. L. A. DE; ANTUNES, A. F. B.; ARAKI, H.; CHEN, QI. Synergistic Use of Ikonos-II and Lidar Data for Mapping a Complex Urban Environment. **Revue Française de Photogrammétrie et de Télédétection** (no prelo).

LUZ, N. B. da; TAVARES JR, J.; ANTUNES, A. F. B. Segmentação Multiresolução e Classificação Orientada a Objetos Aplicados a Imagens Spot-5 para o Mapeamento do Uso da Terra do Estado do Paraná. **Revista Floresta**, v.40, n.2, 2010.

MAACK, R. 1950. Mapa Fitogeográfico do Estado do Paraná. Curitiba, IBPT.

MAEDA, E. E.; FORMAGGIO, A. R.; SHIMABUKURO, Y. E., ARCOVERDE, G. F. B.; HANSEN, M. C. Predicting forest fire in the Brazilian Amazon using MODIS imagery

and artificial neural networks. **International Journal of Applied Earth Observation and Geoinformation**, v. 11, p. 265 – 272. 2009

MAEDA, E.E.; ARCOVERDE, G.F.B.; PELLIKKA, P.K.E.; SHIMABUKURO, Y.E. Fire risk assessment in the Brazilian Amazon using MODIS imagery and change vector analysis. **Applied Geography**, v.31, n.1, p.76-84. 2011.

MALLINIS, G., KOUTSIAS, N., TSAKIRI-STRATI, M., & KARTERIS, M. Object-based classification using Quickbird imagery for delineating forest vegetation polygons in a Mediterranean test site. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.63, n.2, p.237-250. 2008.

MARPU, P.R.; NEUBERT, M.; HEROLD, H.; NIEMEYER, I. Enhanced evaluation of image segmentation results. **Journal of Spatial Science**, v. 55, n. 1, p. 55-68. 2010.

MARTENS, J.; WETS, G.; VANTHIENEN, J.; MUES, C. An initial comparison of a fuzzy neural classifier and a decision tree based classifier. **Expert Systems with Applications**, v. 15, n. 3, p. 375-381. 1998.

MARX, A. Detection and classification of Bark Beetle infestation in pure Norway spruce stands with multi-temporal RapidEye imagery and data mining techniques. **Photogrammetrie Fernerkundung Geoinformation**, n.4, p.243-252. 2010.

MATTOS, P. P. de; OLIVEIRA, M. F.; AGUSTINI, A. F.; BRAZ, E. M.; RIVERA, H.; OLIVEIRA, Y. M. M. de; ROSOT, M. A. D.; GARRASTAZU, M. C. Aceleração do crescimento em diâmetro de espécies da Floresta Ombrófila Mista nos últimos 90 anos. **Pesquisa Florestal Brasileira**, v. 30, n. 64, p. 319-326. 2010.

MATTOS, P. P.; SANTOS, A. T.; RIVERA, H.; OLIVEIRA, Y. M. M. de; ROSOT, M.A.D.; GARRASTAZU, M. C. Crescimento de *Araucaria angustifolia* na Reserva Florestal Embrapa/Epagri, Caçador, SC. **Pesquisa Florestal Brasileira**, n. 55, p. 107 - 114, 2007.

MCINERNEY, D.O.; Nieuwenhuis, M. A comparative analysis of kNN and decision tree methods for the Irish National Forest Inventory. **International Journal of Remote Sensing**. v.30, n.19, p.4937-4955, 2009.

MCIVER, D.K.; FRIEDL, M.A. Using prior probabilities in decision-tree classification of remotely sensed data. **Remote Sensing of Environment**, v.81, n.2, p. 253 - 261. 2002.

MELESSE, A.M.; WENG, Q.H.; THENKABAIL, P.S.; SENAY, G.B. Remote sensing and applications in environmental resources mapping and modeling. **Sensors**, v.7, n.12, p.3209-3241. 2007.

MICHIE, D.; SPIEFELHALTER, D. J.; TAYLOR, C. C. (Eds.) **Machine Learning, Neural and Statistical Classification**. New York: Ellis Horwood, 290 p., 1994.

MITCHELL, T., **Machine Learning**, McGraw-Hill, 1997.

MMA (MINISTÉRIO DO MEIO AMBIENTE, DOS RECURSOS HÍDRICOS E DA AMAZÔNIA LEGAL). **Avaliação e ações prioritárias para a conservação da biodiversidade da Mata Atlântica e Campos Sulinos**. Brasília: Conservation International do Brasil, Fundação Sos Mata Atlântica, Fundação Biodiversitas. 2000. Disponível em: <<http://www.conservation.org.br/publicacoes/files/Sumario.pdf>> Acesso em: 04/05/2010.

MÖLLER, M.; LYMBURNER, L.; VOLK, M. The comparison index: a tool for assessing the accuracy of image segmentation. **International Journal of Applied Earth Observation and Geoinformation**, v. 9, n. 3, p. 311–321. 2007.

MURTHY, S. K. **On growing better decision trees from data**. 288 p. Tese (Doutorado em Ciência da Computação) - Department of Computer Science, Johns Hopkins University, Baltimore, Maryland, 1995.

MYERS, N., MITTERMEIER, R. A., MITTERMEIER, C. G., FONSECA, G. A. B. & KENT, J. Biodiversity hotspots for conservation priorities. **Nature**, v.403, p. 854 - 858. 2000.

NA, X.D.; ZHANG, S.Q.; LI, X.F.; YU, H.A.; LIU, C.Y. Improved land cover mapping using Random Forests combined with LANDSAT Thematic Mapper imagery and ancillary geographic data. **Photogrammetric Engineering and Remote Sensing**, v.76, n.7, p.833-840. 2010.

NASCIMENTO, L. A. do. **Caracterização do uso e cobertura da terra como subsídio para análise de paisagem e de vulnerabilidade de um fragmento de Floresta Ombrófila Mista**. Dissertação (Mestrado em Ciências Florestais) Setor de Ciências Florestais – Universidade Federal do Paraná, Curitiba, 2011. (no prelo).

NEUBERT, M. Segment-based analysis of high resolution satellite and laser scanning data. In: HILTY, L. M.; GILGEN, P. W. (Eds.). **SUSTAINABILITY IN THE INFORMATION SOCIETY. PROCEEDINGS OF THE 15TH INTERNATIONAL SYMPOSIUM INFORMATICS FOR ENVIRONMENTAL PROTECTION**, 15., Zurich. **Proceedings...** Zurich: EMPA, p. 379 – 386, 2001.

NEUBERT, M.; HEROLD, H.; MEINEL, G. Assessing image segmentation quality Concepts, methods and application. In: BLASCHKE, T.; LANG, S.; HAY, G. F. (Ed.) **Object-Based Image Analysis - Spatial Concepts for Knowledge-Driven Remote Sensing Applications**, Berlin: Springer, 2008. p. 760-784.

NEUBERT, M.; HEROLD, H.; MEINEL, G. Evaluation of remote sensing image segmentation quality - Further results and concepts In: International Conference on Object-based Image Analysis, 1., 2006, Salzburg. **Proceedings...** Salzburg: Salzburg University, 2006.

OLIVEIRA, J. C. **Índice para avaliação de segmentação (IAVAS): uma aplicação em agricultura**. Dissertação (Mestrado em Sensoriamento Remoto) – Instituto Nacional de Pesquisas Espaciais. 160p. 2003.

OLIVEIRA, Y. M. M. de. **Investigation of remote sensing for assessing and monitoring the araucaria forest of Brazil**. 247 p. Thesis (Philosophy Doctor, Geography) - University of Oxford, Oxford, UK, 2000.

PESCH, R.; SCHMIDT, G. SCHROEDER, W. WEUSTERMANN, I. Application of CART in ecological landscape mapping: Two case studies. **Ecological Indicators**, v.11, n.1, p.115-122. 2011.

POLAK, M.; ZHANG, H.; PI, M. An evaluation metric for image segmentation of multiple objects. **Image and Vision Computing**, v. 27, n. 8, p. 1223-1227. 2009.

POULIOT, D., LATIFOVIC, R., FERNANDES, R., & OLTROF, I. Evaluation of annual forest disturbance monitoring using a static decision tree approach and 250 m MODIS data. **Remote Sensing of Environment**, v.113, n.8, p.1749-1759. 2009.

PRATT, W. **Digital image processing: PIKS scientific inside**. 4.ed. New York: J. Wiley, 786 p., 2007.

PUNIA, M.; JOSHI, P.K.; PORWAL, M.C. Decision tree classification of land use land cover for Delhi, India using IRS-P6 AWiFS data. **Expert Systems with Applications**, v.38, n.2011, p.5577–5583. 2011.

QUINLAN, J. R. Induction of decision trees. **Machine Learning**, v. 1, n. 1, p.81-106, 1986.

RADOUX, J.; DEFOURNY, P. Quality assessment of segmentation results devoted to object-based classification. In: BLASCHKE, T.; LANG, S.; HAY, G. F. (Ed.) **Object-Based Image Analysis - Spatial Concepts for Knowledge-Driven Remote Sensing Applications**, Berlin: Springer, 2008. p. 257–271.

REITZ, R., KLEIN, R., REIS, A. **Projeto madeira de Santa Catarina**. Convênio SUDESUL/Governo do Estado de Santa Catarina/IBDF. 320 p. 1978.

REITZ, R.; KLEIN, R. Araucariáceas. In: REITZ, R. (Ed.). **Flora Ilustrada Catarinense**. Itajaí: Herbário Barbosa Rodrigues, 1966. p.1-65.

REITZ, R.; KLEIN, R.; REIS, A. **Projeto madeira de Santa Catarina: Levantamento das espécies florestais nativas em Santa Catarina com a possibilidade de incremento e desenvolvimento**. Itajaí: SUDESUL, 1978. 320p. Convênio SUDESUL/Governo do Estado de Santa Catarina/IBDF.

REMPEL, C. **Aplicação do sensoriamento remoto para determinação da evolução da mata nativa da Bacia Hidrográfica do Rio Forqueta-RS**. 87p.



Dissertação (Mestrado em Sensoriamento Remoto) Curso de Pós-Graduação em Sensoriamento Remoto, Centro Estadual de Pesquisas em Sensoriamento Remoto e Meteorologia, Universidade Federal do Rio Grande do Sul, Porto Alegre, 2000.

RIBEIRO, B. M. G. **Avaliação das imagens WorldView-II para o mapeamento da cobertura do solo urbano utilizando o sistema InterIMAGE**. 177 p. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2010. Disponível em: <<http://urlib.net/8JMKD3MGP7W/3826JHA>>. Acesso em: 19/10/2011.

RIZZINI, C. T. Plantas do Brasil: **Árvores e madeiras úteis do Brasil - manual de dendrologia brasileira**. São Paulo: Edgar Blucher, 296p. 1978.

ROGAN, J.; FRANKLIN, J.; ROBERTS, D.A. A comparison of methods for monitoring multitemporal vegetation change using Thematic Mapper imagery. **Remote Sensing of Environment**, v.80, n.1, p.143-156. 2002.

ROKACH L., MAIMON O. **Data mining with decision trees: theory and applications**. World Scientific Publishing, Singapore, 244p. 2008

RONGQUN, Z.; DAOLIN, Z. Study of land cover classification based on knowledge rules using high-resolution remote sensing images, **Expert Systems with Applications**, v.38, n.4, p.3647-3652. 2011.

ROSEMBACK, R. Análise da dinâmica da cobertura vegetal na região sul do Brasil a partir de dados MODIS-TERRA. Dissertação (Mestrado em Sensoriamento Remoto) - Instituto Nacional de Pesquisas Espaciais, São José dos Campos, 2007.

ROSEMBACK, R.; FERREIRA, N. J.; SHIMABUKURO, Y. E.; CONFORTE, J. C. Análise da dinâmica da cobertura vegetal na região Sul do Brasil a partir de dados MODIS/Terra. **Revista Brasileira de CARTografia**, v.62, n.2, p.401-416, 2010.

ROSOT, M. A. D. Manejo florestal de uso múltiplo: uma alternativa contra a extinção da Floresta com Araucária? **Pesquisa Florestal Brasileira**, n. 55, p.75 - 85. 2007.

ROSOT, M. A. D.; MATTOS, P. P.; GARRASTAZU, M. C.; SHIMIZU, J. Y. **Monitoramento na Reserva Florestal da Embrapa/Epagri (RFEE) em Caçador, SC**. Série Documentos Embrapa Florestas, 158, 35p. 2007a.

ROSOT, M. A. D.; RIVERA, H. A.; OLIVEIRA, Y. M. M. de; DLUGOSZ, F. L.; ROSOT, N. C. Discriminating sub-typologies in Araucarian forests in Brazil: a comparison between remote sensing and phytosociological approaches. In: INTERNATIONAL SYMPOSIUM ON REMOTE SENSING OF ENVIRONMENT, 32., 2007, San José. **Proceedings...** Tucson: International Center for Remote Sensing of Environment. 2007b.



ROSOT, N. C.; DLUGOSZ, F. L.; ROSOT, M. A. D.; KURASZ, G.; OLIVEIRA, Y. M. M. de. Ações de recuperação em área degradada por fogo em Floresta Ombrófila Mista: resultados parciais. **Pesquisa Florestal Brasileira**, n. 55, p. 23-30, 2007c.

RUSSELL, S. J.; NORVIG, P. **Artificial intelligence**: a modern approach. New Jersey: Prentice Hall, 1081 p., 2003.

SAATCHI, S. S.; HOUGHTON, R. A.; ALVALA, R. C. D. S.; SOARES, J. V.; YU, Y. Distribution of aboveground live biomass in the Amazon basin. **Global Change Biology**, v.13, n.4, p.816-837. 2007.

SADER, S. A.; ATONE, T. A.; JOYCE, A. T. Remote-sensing of tropical forests - an overview of research and applications using nonphotographic sensors. **Photogrammetric Engineering and Remote Sensing**, v.56, n.10, p.1343-1351. 1990.

SANTOS, D. **Extração semi-automática do cruzamento de vias aéreas urbanas com uso de ortoimagens de alta resolução espacial**. 122p. Dissertação (Mestrado em Ciências Geodésicas) - Curso de Pós-graduação em Ciências Geodésicas, Universidade Federal do Paraná, Curitiba. 2010

SCHIEWE, J.; TUFTE, L.; EHLERS, M. Potential and problems of multi-scale segmentation methods in remote sensing. **GeoBIT/GIS** v. 6, p. 34-39, 2001.

SCHÖPFER, E. LANG, S., ALBRECHT, F. Object-fate analysis: Spatial relationships for the assessment of object transition and correspondence. In: BLASCHKE, T.; LANG, S.; HAY, G. F. (Ed.) **Object-Based Image Analysis - Spatial Concepts for Knowledge-Driven Remote Sensing Applications**, Berlin: Springer, 2008. p. 785-801.

SESNIE, S.E.; FINEGAN, B.; GESSLER, P.E.; THESSLER, S.; BENDANA, Z.R.; SMITH, A.M.S. The multispectral separability of Costa Rican rainforest types with support vector machines and Random Forest decision trees. **International Journal of Remote Sensing**, v.31, n.11, p.2885-2909. 2010.

SESNIE, S.E.; GESSLER, P.E.; FINEGAN, B.; THESSLER, S. Integrating LANDSAT TM and SRTM-DEM derived variables with decision trees for habitat classification and change detection in complex neotropical environments. **Remote Sensing of Environment**, v.112, n.5, p.2145-2159. 2008.

SHARMA, A.; SAHNI, S. A Comparative Study of Classification Algorithms for Spam Email Data Analysis. **International Journal on Computer Science and Engineering**, vol.3; n.5, 2011.

SILVA, F. F.; SERVELLO, E. L.; FONSECA, L. M. G.; SANTOS, J. R.; KUPLICH, T. M. Análise da distribuição de copas de Araucária (*Araucaria angustifolia* Bert. O. Ktz.) a partir da fusão de imagens HRC-CCD/CBERS-2B. In: SIMPÓSIO BRASILEIRO DE

SENSORIAMENTO REMOTO, 14. (SBSR), 2009, Natal. Anais... São José dos Campos: INPE, 2009. p. 2217-2223. Disponível em: <<http://urlib.net/dpi.inpe.br/sbsr@80/2008/11.18.00.59.13>>. Acesso em: 19/05/2011.

SILVA, M.P.D.; CAMARA, G.; ESCADA, M.I.S.; DE SOUZA, R.C.M. Remote-sensing image mining: detecting agents of land-use change in tropical forest areas. **International Journal of Remote Sensing**, v.29, n.16, p.4803-4822. 2008.

SIMARD, M.; SAATCHI, S.S.; DE GRANDI, G. The use of decision tree and multiscale texture for classification of JERS-1 SAR data over tropical forest. **IEEE Transactions on Geoscience and Remote Sensing**, v.38, n.5, p.2310-2321. 2000.

SMITH, A. Image segmentation scale parameter optimization and land cover classification using the Random Forest algorithm. **Journal of Spatial Science**. v. 55, n. 1. 2010.

STURM, U.; WEIDNER, U. Further investigations on segmentation quality assessment for remote sensing applications. In: High Resolution Earth Imaging for Geospatial Information, 2009, Hannover. **Proceedings...** Hannover: ISPRS, 2009.

SUGUMARAN, R. PAVULURI, M. K. ZERR, D. The use of high-resolution imagery for identification of urban climax forest species using traditional and rule-based classification approach. **IEEE Transactions on Geoscience and Remote Sensing**, v.41, n.9, p.1933 – 1939. 2003

SYED, S.; DARE, P.; JONES, S. Automatic classification of land cover features with high resolution imagery and lidar data: an object-oriented approach. In: Proceedings of Spatial Science Conference 2005: spatial Intelligence, innovation and praxis, 2005, Melbourne. **Proceedings...** Melbourne: Spatial Sciences Institute, p. 512 - 522. 2005. Disponível em: <[http://www.definiens.com/resources/es\\_scientific\\_paper2005.php](http://www.definiens.com/resources/es_scientific_paper2005.php)> Acesso em 03/07/2008.

TAYLOR, S.; VEAL, M.; GRIFT, T.; MC DONALD, T.; CORLEY, F. PRECISION FORESTRY: Operational tactics for today and tomorrow. In: Forest engineering challenges: a global perspective, 25, 2002. Corvallis, OR. **Proceedings...** Portland, OR: Council of Forest Engineers, 2002. Disponível em : <[www.eng.auburn.edu/files/file169.pdf](http://www.eng.auburn.edu/files/file169.pdf)> Acesso em: 13/09/2010.

TOOKE, T. R.; COOPS, N. C.; GOODWIN, N. R.; VOOGT, J. A. Extracting urban vegetation characteristics using spectral mixture analysis and decision tree classifications. **Remote Sensing of Environment**, v.113, n.2, p.398-407. 2009.

TOTTRUP, C. Forest and land cover mapping in a tropical highland region. **Photogrammetric Engineering and Remote Sensing**, v.73, n.9, p.1057-1065. 2007.

UTGOFF, P. Decision Trees. In: WILSON, R. A.; KEIL, F. C. (Eds). **The MIT encyclopedia of the cognitive sciences**, Massachusetts: MIT Press, 1104 p., 1999.

WANG K., FRANKLIN S.E., GUO X., CATTET M. Remote sensing of ecology, biodiversity and conservation: a review from the perspective of remote sensing specialists. **Sensors**. v.10, n.11, p.9647-9667. 2010.

WANG, L.; SOUSA, W. P.; GONG, P. Integration of Object-based and Pixel-based Classification for Mapping Magroves with Ikonos-II Imagery. **International Journal of Remote Sensing**, v. 25, n. 24, p.5655 - 5668. 2004.

WASKE, B.; BRAUN, M. Classifier ensembles for land cover mapping using multitemporal SAR imagery. **ISPRS Journal of Photogrammetry and Remote Sensing**. v.64, n.5, p.450-457. 2009.

WATZLAWICK, L. F. Estimativa de Biomassa e Carbono em Floresta Ombrófila Mista Montana, utilizando dados de campo e dados obtidos a partir de imagens do satélite Ikonos-II. 129f. Tese (Doutorado em Ciências Florestais - Manejo Florestal), Setor de Ciências Florestais, Universidade Federal do Paraná, Curitiba, 2003.

WEKA - Waikato Environment for Knowledge Analysis. Disponível em:  
<<http://www.cs.waikato.ac.nz/ml/weka>> Acesso em: 23/08/2011.

WITTEN , I.H., FRANK, E. (Eds.). **Data Mining**: practical machine learning tools and techniques, 2 ed., San Francisco: Morgan Kaufmann, 2005.

WREGE, M. S.; HIGA, R. C. V.; BRITEZ, M. R.; GARRASTAZU, M. C.; SOUSA, V. A.; CARAMORI, P.; RADIN H. B.; BRAGA, H. J. Climate change and conservation of *Araucaria angustifolia* in Brazil. **Unasylva**. v. 60, n.231/232, p.30-33, 2009.

WULDER, M. Optical remote sensing techniques for the assessment of forest inventory and biophysical parameters. **Progress in Physical Geography**, v.22, n.4, p.449–476. 1998.

WULDER, M.; WHITE, J.; GILLIS, M.; WALSWORTH, N.; HANSEN, M.; POTAPOV, P. Multiscale satellite and spatial information and analysis framework in support of a large-area forest monitoring and inventory update. **Environmental Monitoring and Assessment**, v.170, n.1-4, p. 417-433, 2009.

XIE, Y., SHA, Z., YU, M. Remote sensing imagery in vegetation mapping: a review. **Journal of Plant Ecology**, v.1, n.1, p.9-23. 2008.

YE, N. (Ed.) **The Handbook of data mining**. New Jersey: Lawrence Erlbaum, 689 p., 2003.

YUA, X.; HYYPPÄÄ, J.; VASTARANTA, M.; HOLOPAINEN, M.; VIITALA, R. Predicting individual tree attributes from airborne laser point clouds based on the random forests technique. **ISPRS Journal of Photogrammetry and Remote Sensing**, v.66, n.1, p.28-37. 2011.

ZHANG, Y. J. Evaluation and comparison of different segmentation algorithms. **Pattern Recognition Letters**, v.18, n.10, p.963-974. 1997.

ZHANG, Y.J. A review of recent evaluation methods for image segmentation. In: International Symposium on Signal Processing and Its Applications, 6., Kuala Lumpur. **Proceedings...** Johor: Universiti Teknologi Malaysia, 2001. p. 148 - 151. 2001.

ZHANG, Y.J. A survey on evaluation methods for image segmentation. **Pattern Recognition** v.29, 1335-1346, 1996.

ZHANG, Y.J. **Advances in Image and Video Segmentation**. Hershey: IRM Press, 2006.

ZHANG, Y.J.; GERBRANDS, J.J. Objective and quantitative segmentation evaluation and comparison. **Signal Processing**, v. 39, n. 3, p. 43-54. 1994.

## APÊNDICES

APÊNDICE 1. VALORES DAS MEDIDAS DOS POLÍGONOS DA IMAGEM SEGMENTADA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE I.

Parâmetro de escala	Fator de Forma	No total de poligonos	Comprimento total de linhas (m)	Variância da area (ha)	Faixa de Coincidência (no. pixels)	Centro de massa (m)
50	0,1	16.607	105,00	0,000001	447.674	11,08
50	0,3	15.232	96,84	0,000001	412.517	11,36
50	0,5	12.056	97,99	0,000001	351.060	12,88
50	0,7	6.920	107,08	0,000003	252.811	16,10
50	0,9	3.489	132,35	0,000008	157.398	23,32
150	0,1	1.307	573,47	0,000065	256.763	37,40
150	0,3	1.133	417,04	0,000122	192.358	39,87
150	0,5	711	418,34	0,000634	125.299	52,56
150	0,7	569	424,47	0,000563	98.661	59,67
150	0,9	487	412,21	0,000499	79.311	66,61
250	0,1	466	1.252,12	0,001957	183.594	73,23
250	0,3	331	948,61	0,006095	111.415	90,74
250	0,5	282	763,46	0,005159	88.291	89,39
250	0,7	251	694,94	0,002774	73.981	97,97
250	0,9	196	677,31	0,004022	59.866	109,15
350	0,1	226	2.029,67	0,006402	151.198	115,05
350	0,3	164	1.520,62	0,015187	88.587	141,66
350	0,5	152	1.147,94	0,015509	72.079	134,62
350	0,7	135	1.089,94	0,018290	60.977	148,62
350	0,9	97	1.106,54	0,024992	48.885	179,61
450	0,1	136	3.342,74	0,047642	127.293	176,83
450	0,3	113	1.941,38	0,017710	79.310	174,13
450	0,5	103	1.535,30	0,025524	65.429	169,19
450	0,7	85	1.690,18	0,067484	55.114	227,61
450	0,9	54	1.979,79	0,271739	43.639	281,63
550	0,1	107	3.740,52	0,027574	114.812	189,88
550	0,3	91	2.068,61	0,018051	75.950	182,32
550	0,5	84	1.838,44	0,033320	61.265	197,06
550	0,7	63	1.880,96	0,069933	49.848	245,71
550	0,9	49	2.237,25	0,447084	43.378	291,69

APÊNDICE 2. DIFERENÇAS NAS MEDIDAS DE DISCREPÂNCIA ENTRE OS POLÍGONOS DA IMAGEM SEGMENTADA E DA IMAGEM-REFERÊNCIA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE I. VALORES NÃO NORMALIZADOS.

Parâmetro de escala	Fator de Forma	Nº total de polígonos	Comprimento total de linhas (m)	Variância da area (ha)	Faixa de Coincidência (no. pixels)
50	0,1	16.178	398,336	0,009641	2.450.610,00
50	0,3	14.803	406,497	0,009641	2.485.767,00
50	0,5	11.627	405,343	0,009641	2.547.224,00
50	0,7	6.491	396,254	0,009639	2.645.473,00
50	0,9	3.060	370,987	0,009634	2.740.886,00
150	0,1	878	70,139	0,009576	2.641.521,00
150	0,3	704	86,291	0,009520	2.705.926,00
150	0,5	282	84,991	0,009007	2.772.985,00
150	0,7	140	78,861	0,009079	2.799.623,00
150	0,9	58	91,125	0,009142	2.818.973,00
250	0,1	37	748,783	0,007684	2.714.690,00
250	0,3	98	445,274	0,003546	2.786.869,00
250	0,5	147	260,129	0,004483	2.809.993,00
250	0,7	178	191,610	0,006868	2.824.303,00
250	0,9	233	173,974	0,005619	2.838.418,00
350	0,1	203	1.526,341	0,003240	2.747.086,00
350	0,3	265	1.017,286	0,005545	2.809.697,00
350	0,5	277	644,602	0,005868	2.826.205,00
350	0,7	294	586,604	0,008648	2.837.307,00
350	0,9	332	603,203	0,015351	2.849.399,00
450	0,1	293	2.839,409	0,038000	2.770.991,00
450	0,3	316	1.438,045	0,008069	2.818.974,00
450	0,5	326	1.031,971	0,015882	2.832.855,00
450	0,7	344	1.186,848	0,057842	2.843.170,00
450	0,9	375	1.476,455	0,262097	2.854.645,00
550	0,1	322	3.237,190	0,017932	2.783.472,00
550	0,3	338	1.565,281	0,008409	2.822.334,00
550	0,5	345	1.335,102	0,023678	2.837.019,00
550	0,7	366	1.377,629	0,060291	2.848.436,00
550	0,9	380	1.733,920	0,437442	2.854.906,00



APÊNDICE 3. VALORES NORMALIZADOS DAS MEDIDAS DE DISCREPÂNCIA DA SEGMENTAÇÃO DA IMAGEM E RESULTADO DO ÍNDICE IAVAS, OBTIDOS NA FASE I DA AVALIAÇÃO QUANTITATIVA DA SEGMENTAÇÃO.

Parâmetro de escala	Fator de Forma	Nº total de polígonos	Comprimento total de linhas (m)	Variância da área (ha)	Centro de massa (m)	Faixa de Coincidência (no. pixels)	IAVAS
50	0,1	3,700	0,412	0,072	0,000	0,000	4,184
50	0,3	3,385	0,422	0,072	0,325	0,003	4,207
50	0,5	2,657	0,421	0,072	0,892	0,022	4,064
50	0,7	1,480	0,409	0,072	1,800	0,061	3,822
50	0,9	0,693	0,378	0,072	2,681	0,149	3,973
150	0,1	0,193	0,000	0,071	1,763	0,321	<b>2,348</b>
150	0,3	0,153	0,020	0,070	2,358	0,351	2,952
150	0,5	0,056	0,019	0,065	2,978	0,505	3,622
150	0,7	0,024	0,011	0,065	3,224	0,592	3,916
150	0,9	0,005	0,026	0,066	3,402	0,676	4,176
250	0,1	0,000	0,852	0,050	2,439	0,757	4,098
250	0,3	0,014	0,471	0,003	3,106	0,970	4,565
250	0,5	0,025	0,239	0,014	3,320	0,954	4,551
250	0,7	0,032	0,153	0,041	3,452	1,059	4,736
250	0,9	0,045	0,130	0,027	3,582	1,195	4,979
350	0,1	0,038	1,828	0,000	2,738	1,267	5,871
350	0,3	0,052	1,189	0,026	3,317	1,591	6,175
350	0,5	0,055	0,721	0,029	3,469	1,505	5,780
350	0,7	0,059	0,648	0,061	3,572	1,675	6,015
350	0,9	0,068	0,669	0,136	3,684	2,053	6,609
450	0,1	0,059	3,477	0,389	2,959	2,019	8,903
450	0,3	0,064	1,717	0,054	3,402	1,986	7,224
450	0,5	0,066	1,208	0,141	3,531	1,926	6,872
450	0,7	0,070	1,402	0,611	3,626	2,638	8,347
450	0,9	0,077	1,766	2,897	3,732	3,296	11,768
550	0,1	0,065	3,976	0,164	3,075	2,178	9,459
550	0,3	0,069	1,877	0,058	3,434	2,086	7,524
550	0,5	0,071	1,588	0,229	3,569	2,266	7,722
550	0,7	0,075	1,642	0,639	3,675	2,858	8,888
550	0,9	0,079	2,089	4,860	3,734	3,418	14,180

APÊNDICE 4. VALORES DAS MEDIDAS DOS POLÍGONOS DA IMAGEM SEGMENTADA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE II.

Parâmetro de escala	Fator de Forma	Nº total de poligonos	Comprimento total de linhas (m)	Variância da area (ha)	Faixa de Coincidência (no. pixels)	Centro de massa (m)
75	0,1	6.292	201,51	0,000004	363.932	17,08
75	0,3	6.059	173,86	0,000003	328.194	17,41
75	0,5	4.291	171,42	0,000009	252.562	20,28
75	0,7	2.436	188,31	0,000021	171.985	26,63
75	0,9	1.683	203,22	0,000030	122.524	34,03
100	0,1	3.167	331,07	0,000013	314.495	25,16
100	0,3	3.061	254,73	0,000012	269.123	24,83
100	0,5	1.987	258,78	0,000054	188.921	31,88
100	0,7	1.308	273,79	0,000082	135.314	37,70
100	0,9	1.001	278,90	0,000095	101.274	45,29
125	0,1	1.946	466,99	0,000036	281.386	32,64
125	0,3	1.728	360,83	0,000047	221.398	33,66
125	0,5	1.108	339,63	0,000124	151.762	41,66
125	0,7	832	349,52	0,000231	113.642	47,69
125	0,9	671	352,05	0,000224	87.815	55,24
150	0,1	1.308	603,14	0,000068	255.926	38,75
150	0,3	1.134	442,35	0,000128	191.828	41,78
150	0,5	713	455,14	0,001097	124.971	55,43
150	0,7	570	456,00	0,000577	98.363	62,20
150	0,9	488	435,29	0,000484	79.189	68,63
175	0,1	951	747,75	0,000128	235.715	47,60
175	0,3	743	585,31	0,000377	162.687	55,65
175	0,5	532	552,62	0,001879	111.385	66,60
175	0,7	457	501,72	0,000723	91.815	70,05
175	0,9	379	507,67	0,001509	72.804	77,97
200	0,1	707	976,97	0,000663	213.366	58,44
200	0,3	556	686,08	0,000849	142.822	64,61
200	0,5	418	629,19	0,001768	101.594	74,81
200	0,7	358	590,21	0,002083	84.354	80,78
200	0,9	295	593,32	0,002207	67.727	90,33
225	0,1	579	1.092,52	0,001142	201.449	64,71
225	0,3	412	849,39	0,002404	123.708	80,36
225	0,5	354	687,85	0,002181	94.904	80,58
225	0,7	293	666,09	0,002595	79.130	90,81
225	0,9	244	668,75	0,003851	63.277	103,23

APÊNDICE 5. DIFERENÇAS NAS MEDIDAS DE DISCREPÂNCIA ENTRE OS POLÍGONOS DA IMAGEM SEGMENTADA E DA IMAGEM-REFERÊNCIA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE II. VALORES NÃO NORMALIZADOS.

Parâmetro de escala	Fator de Forma	Nº total de polígonos	Comprimento total de linhas (m)	Variância da área (ha)	Faixa de Coincidência (no. pixels)
75	0,1	9.215	301,82	0,009638	2.534.352
75	0,3	8.578	329,48	0,009638	2.570.090
75	0,5	6.162	331,91	0,009632	2.645.722
75	0,7	3.756	315,03	0,009620	2.726.299
75	0,9	2.363	300,11	0,009612	2.775.760
100	0,1	4.522	172,27	0,009629	2.583.789
100	0,3	4.204	248,60	0,009629	2.629.161
100	0,5	2.856	244,55	0,009587	2.709.363
100	0,7	1.831	229,54	0,009559	2.762.970
100	0,9	1.209	224,44	0,009547	2.797.010
125	0,1	2.642	36,34	0,009606	2.616.898
125	0,3	2.292	142,51	0,009594	2.676.886
125	0,5	1.478	163,70	0,009517	2.746.522
125	0,7	1.029	153,81	0,009410	2.784.642
125	0,9	650	151,29	0,009418	2.810.469
150	0,1	1.627	99,81	0,009573	2.642.358
150	0,3	1.378	60,99	0,009513	2.706.456
150	0,5	855	48,19	0,008544	2.773.313
150	0,7	549	47,34	0,009064	2.799.921
150	0,9	348	68,04	0,009157	2.819.095
175	0,1	1.058	244,42	0,009514	2.662.569
175	0,3	819	81,98	0,009265	2.735.597
175	0,5	504	49,28	0,007762	2.786.899
175	0,7	318	1,61	0,008919	2.806.469
175	0,9	145	4,34	0,008133	2.825.480
200	0,1	701	473,63	0,008978	2.684.918
200	0,3	487	182,75	0,008793	2.755.462
200	0,5	289	125,86	0,007874	2.796.690
200	0,7	156	86,88	0,007558	2.813.930
200	0,9	3	89,99	0,007434	2.830.557
225	0,1	494	589,19	0,008500	2.696.835
225	0,3	264	346,06	0,007238	2.774.576
225	0,5	162	184,52	0,007461	2.803.380
225	0,7	49	162,75	0,007046	2.819.154
225	0,9	77	165,42	0,005791	2.835.007

APÊNDICE 6. VALORES NORMALIZADOS DAS MEDIDAS DE DISCREPÂNCIA DA SEGMENTAÇÃO DA IMAGEM E RESULTADO DO ÍNDICE IAVAS, OBTIDOS NA FASE II DA AVALIAÇÃO QUANTITATIVA DA SEGMENTAÇÃO.

Parâmetro de escala	Fator de Forma	No total de polígonos	Comprimento total de linhas (m)	Variância da área (ha)	Centro de massa (m)	Faixa de Coincidência (no. pixels)	IAVAS
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
75	0,1	2,628	0,458	0,100	0,856	0,087	4,129
75	0,3	2,446	0,500	0,100	1,222	0,091	4,359
75	0,5	1,757	0,504	0,100	1,995	0,133	4,488
75	0,7	1,071	0,478	0,099	2,819	0,225	4,692
75	0,9	0,673	0,455	0,099	3,325	0,331	4,884
100	0,1	1,289	0,260	0,100	1,362	0,203	3,214
100	0,3	1,198	0,377	0,100	1,826	0,199	3,699
100	0,5	0,814	0,371	0,099	2,646	0,300	4,230
100	0,7	0,521	0,348	0,098	3,194	0,384	4,546
100	0,9	0,344	0,340	0,098	3,542	0,494	4,818
125	0,1	0,753	0,053	0,099	1,700	0,311	2,917
125	0,3	0,653	0,215	0,099	2,314	0,326	3,607
125	0,5	0,421	0,247	0,098	3,026	0,442	4,233
125	0,7	0,293	0,232	0,096	3,416	0,529	4,565
125	0,9	0,185	0,228	0,096	3,680	0,638	4,827
150	0,1	0,250	0,105	0,099	1,952	0,380	2,785
150	0,3	0,200	0,129	0,098	2,611	0,416	3,454
150	0,5	0,080	0,127	0,090	3,297	0,599	4,192
150	0,7	0,039	0,118	0,091	3,569	0,702	4,519
150	0,9	0,016	0,137	0,092	3,767	0,802	4,813
175	0,1	0,301	0,370	0,098	2,167	0,527	3,464
175	0,3	0,233	0,123	0,094	2,914	0,644	4,007
175	0,5	0,143	0,073	0,070	3,439	0,802	4,527
175	0,7	0,090	0,000	0,088	3,639	0,852	4,669
175	0,9	0,041	0,004	0,076	3,833	0,966	4,920
200	0,1	0,199	0,720	0,089	2,396	0,684	4,088
200	0,3	0,138	0,276	0,087	3,117	0,773	4,391
200	0,5	0,082	0,190	0,072	3,539	0,920	4,803
200	0,7	0,044	0,130	0,067	3,715	1,007	4,963
200	0,9	0,000	0,135	0,065	3,885	1,145	5,230
225	0,1	0,140	0,896	0,082	2,518	0,774	4,411
225	0,3	0,074	0,525	0,062	3,313	1,001	4,976
225	0,5	0,045	0,279	0,066	3,607	1,004	5,001
225	0,7	0,013	0,246	0,059	3,769	1,151	5,238
225	0,9	0,021	0,250	0,040	3,931	1,331	5,572
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

APÊNDICE 7. VALORES DAS MEDIDAS DOS POLÍGONOS DA IMAGEM SEGMENTADA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE III.

(continua)

Parâmetro de escala	Fator de Forma	Nº total de polígonos	Comprimento total de linhas (m)	Variância da área (ha)	Faixa de Coincidência (no. pixels)	Centro de massa (m)
130	0,1	1.770	479,16	0,000039	547.009	32,58
130	0,3	1.570	367,71	0,000053	494.859	34,01
130	0,5	986	356,75	0,000216	432.199	43,81
130	0,7	769	347,19	0,000323	403.240	49,23
130	0,9	636	345,22	0,000246	382.207	56,35
135	0,1	1.618	503,47	0,000047	542.089	33,57
135	0,3	1.466	381,55	0,000070	489.609	34,72
135	0,5	914	369,91	0,000256	428.991	45,63
135	0,7	707	370,80	0,000367	399.769	52,52
135	0,9	608	357,71	0,000284	381.190	58,48
140	0,1	1.504	525,10	0,000055	537.799	34,47
140	0,3	1.349	396,75	0,000081	483.665	36,55
140	0,5	829	382,01	0,000280	424.032	47,59
140	0,7	661	390,33	0,000408	397.394	55,56
140	0,9	570	367,58	0,000312	380.132	59,95
145	0,1	2.186	555,35	0,000061	533.226	35,98
145	0,3	1.229	410,75	0,000090	478.981	38,07
145	0,5	762	404,12	0,000453	418.408	50,05
145	0,7	623	400,46	0,000436	395.507	57,54
145	0,9	523	390,55	0,000397	378.110	63,46
155	0,1	1.223	602,23	0,000077	1.107.822	39,78
155	0,3	1.022	447,51	0,000196	466.680	43,21
155	0,5	663	439,23	0,000860	413.189	55,81
155	0,7	547	433,14	0,000572	391.050	60,66
155	0,9	474	412,93	0,000530	375.644	66,87
160	0,1	1.133	629,35	0,000079	522.530	40,95
160	0,3	938	475,76	0,000228	460.857	45,66
160	0,5	628	455,03	0,001002	406.821	57,48
160	0,7	530	436,47	0,000566	390.475	61,67
160	0,9	453	420,95	0,000532	375.054	68,21
165	0,1	1.071	652,21	0,000087	519.786	42,37
165	0,3	864	508,23	0,000287	455.738	48,61
165	0,5	590	477,62	0,001353	406.821	60,96
165	0,7	512	445,47	0,000567	389.438	63,02
165	0,9	419	445,08	0,000987	372.936	71,37

APÊNDICE 7. VALORES DAS MEDIDAS DOS POLÍGONOS DA IMAGEM SEGMENTADA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE III.

(conclusão)

Parâmetro de escala	Fator de Forma	Nº total de poligonos	Comprimento total de linhas (m)	Variância da area (ha)	Faixa de Coincidência (no. pixels)	Centro de massa (m)
170	0,1	1.021	669,23	0,000091	517.341	43,67
170	0,3	783	526,53	0,000314	451.040	51,30
170	0,5	556	492,58	0,001527	405.295	62,23
170	0,7	488	452,75	0,000661	388.025	65,15
170	0,9	402	456,58	0,001028	372.213	73,35

APÊNDICE 8. DIFERENÇAS NAS MEDIDAS DE DISCREPÂNCIA ENTRE OS POLÍGONOS DA IMAGEM SEGMENTADA E DA IMAGEM-REFERÊNCIA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE III. VALORES NÃO NORMALIZADOS.

(continua)

Parâmetro de escala	Fator de Forma	Nº total de polígonos	Comprimento total de linhas (m)	Variância da área (ha)	Faixa de Coincidência (no. pixels)
130	0,1	1.341	24,18	0,009603	2.351.275
130	0,3	1.141	135,62	0,009589	2.403.425
130	0,5	557	146,58	0,009426	2.466.085
130	0,7	340	156,15	0,009319	2.495.044
130	0,9	207	158,12	0,009396	2.516.077
135	0,1	1.189	0,13	0,009595	2.356.195
135	0,3	1.037	121,78	0,009571	2.408.675
135	0,5	485	133,42	0,009386	2.469.293
135	0,7	278	132,53	0,009274	2.498.515
135	0,9	179	145,62	0,009357	2.517.094
140	0,1	1.075	21,77	0,009587	2.360.485
140	0,3	920	106,59	0,009560	2.414.619
140	0,5	400	121,32	0,009361	2.474.252
140	0,7	232	113,00	0,009233	2.500.890
140	0,9	141	135,75	0,009330	2.518.152
145	0,1	1.757	52,02	0,009580	2.365.058
145	0,3	800	92,58	0,009552	2.419.303
145	0,5	333	99,21	0,009189	2.479.876
145	0,7	194	102,87	0,009206	2.502.777
145	0,9	94	112,79	0,009245	2.520.174
155	0,1	794	98,90	0,009565	1.790.462
155	0,3	593	55,83	0,009446	2.431.604
155	0,5	234	64,10	0,008781	2.485.095
155	0,7	118	70,19	0,009070	2.507.234
155	0,9	45	90,40	0,009112	2.522.640
160	0,1	704	126,01	0,009562	2.375.754
160	0,3	509	27,58	0,009414	2.437.427
160	0,5	199	48,30	0,008640	2.491.463
160	0,7	101	66,87	0,009076	2.507.809
160	0,9	24	82,39	0,009110	2.523.230
165	0,1	642	148,88	0,009554	2.378.498
165	0,3	435	4,90	0,009354	2.442.546
165	0,5	161	25,72	0,008289	2.491.463
165	0,7	83	57,86	0,009075	2.508.846
165	0,9	10	58,25	0,008655	2.525.348



APÊNDICE 8. MEDIDAS DE DISCREPÂNCIA ENTRE OS POLÍGONOS DA IMAGEM SEGMENTADA E DA IMAGEM-REFERÊNCIA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE III. VALORES NÃO NORMALIZADOS.

(conclusão)

Parâmetro de escala	Fator de Forma	Nº total de poligonos	Comprimento total de linhas (m)	Variância da area (ha)	Faixa de Coincidência (no. pixels)
170	0,1	592	165,90	0,009550	2.380.943
170	0,3	354	23,20	0,009328	2.447.244
170	0,5	127	10,75	0,008115	2.492.989
170	0,7	59	50,58	0,008980	2.510.259
170	0,9	27	46,75	0,008613	2.526.071

APÊNDICE 9. VALORES NORMALIZADOS DAS MEDIDAS DE DISCREPÂNCIA DA SEGMENTAÇÃO DA IMAGEM E RESULTADO DO ÍNDICE IAVAS, OBTIDOS NA FASE III DA AVALIAÇÃO QUANTITATIVA DA SEGMENTAÇÃO.

(continua)

Parâmetro de escala	Fator de Forma	Nº total de polígonos	Comprimento total de linhas (m)	Variância da área (ha)	Centro de massa (m)	Faixa de Coincidência (no. pixels)	IAVAS
<b>50</b>	<b>0,1</b>	5,740	0,721	0,128	3,597	0,000	10,186
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
<b>130</b>	<b>0,1</b>	0,475	0,044	0,127	3,056	0,378	4,080
<b>130</b>	<b>0,3</b>	0,404	0,245	0,127	3,340	0,403	4,520
<b>130</b>	<b>0,5</b>	0,197	0,265	0,124	3,682	0,576	4,843
<b>130</b>	<b>0,7</b>	0,120	0,282	0,122	3,839	0,671	5,034
<b>130</b>	<b>0,9</b>	0,072	0,286	0,123	3,954	0,796	5,232
<b>135</b>	<b>0,1</b>	0,421	0,000	0,127	3,083	0,396	4,026
<b>135</b>	<b>0,3</b>	0,367	0,220	0,127	3,369	0,416	4,498
<b>135</b>	<b>0,5</b>	0,171	0,241	0,123	3,699	0,608	4,842
<b>135</b>	<b>0,7</b>	0,098	0,240	0,121	3,858	0,729	5,045
<b>135</b>	<b>0,9</b>	0,062	0,263	0,122	3,960	0,834	5,241
<b>140</b>	<b>0,1</b>	0,380	0,039	0,127	3,106	0,412	4,064
<b>140</b>	<b>0,3</b>	0,325	0,193	0,126	3,401	0,448	4,494
<b>140</b>	<b>0,5</b>	0,141	0,219	0,122	3,726	0,642	4,851
<b>140</b>	<b>0,7</b>	0,081	0,204	0,120	3,871	0,782	5,059
<b>140</b>	<b>0,9</b>	0,049	0,245	0,122	3,965	0,860	5,241
<b>145</b>	<b>0,1</b>	0,622	0,094	0,127	3,131	0,438	4,412
<b>145</b>	<b>0,3</b>	0,283	0,167	0,126	3,427	0,475	4,478
<b>145</b>	<b>0,5</b>	0,117	0,179	0,119	3,757	0,686	4,858
<b>145</b>	<b>0,7</b>	0,068	0,186	0,119	3,882	0,817	5,072
<b>145</b>	<b>0,9</b>	0,032	0,204	0,120	3,976	0,921	5,254
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
<b>155</b>	<b>0,1</b>	<b>0,281</b>	<b>0,179</b>	<b>0,127</b>	<b>0,000</b>	<b>0,505</b>	<b>1,091</b>
<b>155</b>	<b>0,3</b>	0,209	0,101	0,124	3,494	0,565	4,493
<b>155</b>	<b>0,5</b>	0,082	0,116	0,111	3,785	0,787	4,881
<b>155</b>	<b>0,7</b>	0,041	0,127	0,117	3,906	0,872	5,062
<b>155</b>	<b>0,9</b>	0,015	0,163	0,118	3,990	0,981	5,267
<b>160</b>	<b>0,1</b>	0,249	0,228	0,127	3,189	0,525	4,318
<b>160</b>	<b>0,3</b>	0,180	0,050	0,124	3,525	0,608	4,487
<b>160</b>	<b>0,5</b>	0,070	0,087	0,108	3,820	0,816	4,901
<b>160</b>	<b>0,7</b>	0,035	0,121	0,117	3,909	0,890	5,071
<b>160</b>	<b>0,9</b>	0,007	0,149	0,117	3,993	1,005	5,272
<b>165</b>	<b>0,1</b>	0,227	0,269	0,126	3,204	0,550	4,377
<b>165</b>	<b>0,3</b>	0,153	0,009	0,122	3,553	0,660	4,498

APÊNDICE 9. VALORES NORMALIZADOS DAS MEDIDAS DE DISCREPÂNCIA DA SEGMENTAÇÃO DA IMAGEM E RESULTADO DO ÍNDICE IAVAS, OBTIDOS NA FASE III DA AVALIAÇÃO QUANTITATIVA DA SEGMENTAÇÃO.

(conclusão)

Parâmetro de escala	Fator de Forma	Nº total de polígonos	Comprimento total de linhas	Variância da área	Centro de massa	Faixa de Coincidência	IAVAS
<b>165</b>	<b>0,5</b>	0,056	0,046	0,101	3,820	0,877	4,901
<b>165</b>	<b>0,7</b>	0,028	0,104	0,117	3,915	0,914	5,078
<b>165</b>	<b>0,9</b>	0,002	0,105	0,108	4,005	1,061	5,281
<b>170</b>	<b>0,1</b>	0,209	0,300	0,126	3,218	0,573	4,426
<b>170</b>	<b>0,3</b>	0,125	0,042	0,122	3,579	0,708	4,575
<b>170</b>	<b>0,5</b>	0,044	0,019	0,098	3,828	0,900	4,889
<b>170</b>	<b>0,7</b>	0,020	0,091	0,115	3,922	0,951	5,099
<b>170</b>	<b>0,9</b>	0,009	0,084	0,108	4,008	1,095	5,304
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

APÊNDICE 10. VALORES DAS MEDIDAS DOS POLÍGONOS DA IMAGEM SEGMENTADA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE IV.

Parâmetro de escala	Fator de Forma	Nº total de poligonos	Comprimento total de linhas (m)	Variância da area (ha)	Faixa de Coincidência (no. pixels)	Centro de massa (m)
151	0,0	1.021	906,38	0,000431	257.092	49,60
151	0,1	1.288	577,73	0,000067	254.599	38,03
151	0,2	1.297	499,33	0,000107	230.653	38,54
152	0,0	1.006	905,91	0,000431	255.627	50,26
152	0,1	1.268	584,98	0,000072	252.937	38,95
152	0,2	1.279	505,32	0,000110	229.775	38,51
153	0,0	984	932,05	0,000447	254.259	50,36
153	0,1	1.253	585,98	0,000072	252.504	39,04
153	0,2	1.244	514,00	0,000113	227.904	39,21
154	0,0	965	924,99	0,000449	253.030	51,55
154	0,1	1.239	593,04	0,000075	251.504	39,50
154	0,2	1.225	517,04	0,000116	226.985	39,42
155	0,0	951	939,28	0,000456	253.074	51,67
155	0,2	1.215	517,81	0,000116	226.372	39,45
156	0,0	941	962,05	0,000514	252.176	52,81
156	0,1	1.207	609,71	0,000075	250.890	40,02
156	0,2	1.189	524,36	0,000115	223.821	40,28
157	0,0	932	994,73	0,000543	252.305	53,60
157	0,1	1.182	619,23	0,000076	249.854	40,29
157-	0,2	1.165	527,60	0,000119	222.321	40,63
158	0,0	918	981,15	0,000534	251.542	52,85
158	0,1	1.163	611,00	0,000074	249.267	40,09
158	0,2	1.150	528,84	0,000128	221.188	40,84
159	0,0	909	979,76	0,000534	251.178	52,84
159	0,1	1.152	621,36	0,000074	248.364	40,42
159	0,2	1.138	532,52	0,000131	221.005	40,96

APÊNDICE 11. DIFERENÇAS NAS MEDIDAS DE DISCREPÂNCIA ENTRE OS POLÍGONOS DA IMAGEM SEGMENTADA E DA IMAGEM-REFERÊNCIA, OBTIDOS POR MEIO DA AVALIAÇÃO DA SEGMENTAÇÃO, NA FASE IV. VALORES NÃO NORMALIZADOS.

Parâmetro de escala	Fator de Forma	Nº total de poligonos	Comprimento total de linhas (m)	Variância da area (ha)	Faixa de Coincidência (no. pixels)
151	0,0	592	403,05	0,009211	2.641.192
151	0,1	859	74,39	0,009575	2.643.685
151	0,2	868	4,01	0,009535	2.667.631
152	0,0	577	402,57	0,009210	2.642.657
152	0,1	839	81,64	0,009570	2.645.347
152	0,2	850	1,99	0,009531	2.668.509
153	0,0	555	428,71	0,009195	2.644.025
153	0,1	824	82,65	0,009570	2.645.780
153	0,2	815	10,67	0,009528	2.670.380
154	0,0	536	421,65	0,009192	2.645.254
154	0,1	810	89,71	0,009566	2.646.780
154	0,2	796	13,71	0,009525	2.671.299
155	0,0	522	435,95	0,009185	2.645.210
155	0,2	786	14,48	0,009526	2.671.912
156	0,0	512	458,72	0,009127	2.646.108
156	0,1	778	106,38	0,009567	2.647.394
156	0,2	760	21,03	0,009526	2.674.463
157	0,0	503	491,39	0,009098	2.645.979
157	0,1	753	115,89	0,009566	2.648.430
157	0,2	736	24,26	0,009522	2.675.963
158	0,0	489	477,81	0,009108	2.646.742
158	0,1	734	107,66	0,009567	2.649.017
158	0,2	721	25,51	0,009514	2.677.096
159	0,0	480	476,42	0,009107	2.647.106
159	0,1	723	118,02	0,009567	2.649.920
159	0,2	709	29,19	0,009510	2.677.279

APÊNDICE 12. VALORES NORMALIZADOS DAS MEDIDAS DE DISCREPÂNCIA DA SEGMENTAÇÃO DA IMAGEM E RESULTADO DO ÍNDICE IAVAS, OBTIDOS NA FASE IV DA AVALIAÇÃO QUANTITATIVA DA SEGMENTAÇÃO.

Parâmetro de escala	Fator de Forma	No total de polígonos	Comprimento total de linhas (m)	Variância da área (ha)	Centro de massa (m)	Faixa de Coincidência (no, pixels)	IAVAS
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮
151	0,0	0,233	0,800	0,134	5,193	0,741	7,101
151	0,1	0,339	0,147	0,142	5,208	0,518	6,355
151	0,2	0,343	0,008	0,141	5,355	0,528	6,374
152	0,0	0,227	0,799	0,134	5,202	0,753	7,115
152	0,1	0,331	0,162	0,142	5,219	0,536	6,389
152	0,2	0,336	0,004	0,141	5,360	0,527	6,368
153	0,0	0,219	0,851	0,134	5,210	0,755	7,169
153	0,1	0,325	0,164	0,142	5,221	0,538	6,390
153	0,2	0,322	0,021	0,141	5,371	0,541	6,396
154	0,0	0,211	0,837	0,134	5,218	0,778	7,177
154	0,1	0,320	0,178	0,142	5,227	0,546	6,413
154	0,2	0,314	0,027	0,141	5,377	0,545	6,404
155	0,0	0,206	0,865	0,133	5,218	0,780	7,202
155	0,1	0,313	0,196	0,142	0,000	0,552	1,203
155	0,2	0,310	0,028	0,141	5,381	0,545	6,406
155	0,3	0,234	0,111	0,139	3,914	0,618	5,015
155	0,5	0,092	0,127	0,124	4,240	0,860	5,443
155	0,7	0,046	0,139	0,131	4,375	0,953	5,644
155	0,9	0,017	0,179	0,132	4,469	1,073	5,870
156	0,0	0,202	0,910	0,132	5,223	0,802	7,270
156	0,1	0,307	0,211	0,142	5,231	0,556	6,447
156	0,2	0,300	0,041	0,141	5,396	0,561	6,440
157	0,0	0,198	0,975	0,131	5,222	0,818	7,345
157	0,1	0,297	0,230	0,142	5,237	0,562	6,468
157	0,2	0,290	0,048	0,141	5,405	0,568	6,453
158	0,0	0,193	0,948	0,132	5,227	0,803	7,303
158	0,1	0,290	0,213	0,142	5,241	0,558	6,444
158	0,2	0,285	0,050	0,141	5,412	0,572	6,460
159	0,0	0,189	0,945	0,132	5,229	0,803	7,298
159	0,1	0,285	0,234	0,142	5,246	0,564	6,472
159	0,2	0,280	0,058	0,141	5,413	0,574	6,466
⋮	⋮	⋮	⋮	⋮	⋮	⋮	⋮

APÊNDICE 13. ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO E BANDAS DO SATÉLITE IKONOS-II QUE COMPÕEM O CONJUNTO INICIAL DE DADOS DE ENTRADA.

(continua)

Nº	Bandas / atributos dos polígonos da segmentação		Nº	Bandas / atributos dos polígonos da segmentação	
	Nome	Tipo		Nome	Tipo
1	Ikonos-II - Banda do azul	Ik	206	MCNC Dissimilaridade todas as direções (1)	Te
2	Ikonos-II - Banda do verde	Ik	207	MCNC Dissimilaridade todas as direções (2)	Te
3	Ikonos-II - Banda do vermelho	Ik	208	MCNC Dissimilaridade todas as direções (3)	Te
4	Ikonos-II - Banda do infra-vermelho	Ik	209	MCNC Dissimilaridade todas as direções (4)	Te
5	Brilho	Es	210	MCNC Entropia 0°	Te
6	Valor máximo dos pixels (1)	Es	211	MCNC Entropia 0° (1)	Te
7	Valor máximo dos pixels (2)	Es	212	MCNC Entropia 0° (2)	Te
8	Valor máximo dos pixels (3)	Es	213	MCNC Entropia 0° (3)	Te
9	Valor máximo dos pixels (4)	Es	214	MCNC Entropia 0° (4)	Te
10	Diferença Máxima	Es	215	MCNC Entropia 135°	Te
11	Média (1)	Es	216	MCNC Entropia 135° (1)	Te
12	Média (2)	Es	217	MCNC Entropia 135° (2)	Te
13	Média (3)	Es	218	MCNC Entropia 135° (3)	Te
14	Média (4)	Es	219	MCNC Entropia 135° (4)	Te
15	Diferença média com relação aos vizinhos mais claros (1)	Es	220	MCNC Entropia 45°	Te
16	Diferença média com relação aos vizinhos mais claros (2)	Es	221	MCNC Entropia 45° (1)	Te
17	Diferença média com relação aos vizinhos mais claros (3)	Es	222	MCNC Entropia 45° (2)	Te
18	Diferença média com relação aos vizinhos mais claros (4)	Es	223	MCNC Entropia 45° (3)	Te
19	Diferença média com relação aos vizinhos mais escuros (1)	Es	224	MCNC Entropia 45° (4)	Te
20	Diferença média com relação aos vizinhos mais escuros (2)	Es	225	MCNC Entropia 90°	Te
21	Diferença média com relação aos vizinhos mais escuros (3)	Es	226	MCNC Entropia 90° (1)	Te
22	Diferença média com relação aos vizinhos mais escuros (4)	Es	227	MCNC Entropia 90° (2)	Te
23	Diferença média absoluta com relação aos vizinhos mais claros (1)	Es	228	MCNC Entropia 90° (3)	Te
24	Diferença média absoluta com relação aos vizinhos mais claros (2)	Es	229	MCNC Entropia 90° (4)	Te
25	Diferença média absoluta com relação aos vizinhos mais claros (3)	Es	230	MCNC Entropia todas as direções	Te
26	Diferença média absoluta com relação aos vizinhos mais claros (4)	Es	231	MCNC Entropia todas as direções (1)	Te
27	Diferença média com relação à cena(1)	Es	232	MCNC Entropia todas as direções (2)	Te
28	Diferença média com relação à cena(2)	Es	233	MCNC Entropia todas as direções (3)	Te
29	Diferença média com relação à cena(3)	Es	234	MCNC Entropia todas as direções (4)	Te



APÊNDICE 13. ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO E BANDAS DO SATÉLITE IKONOS-II QUE COMPÕEM O CONJUNTO INICIAL DE DADOS DE ENTRADA.

(continuação)

Nº	Bandas / atributos dos polígonos da segmentação		Nº	Bandas / atributos dos polígonos da segmentação	
	Nome	Tipo		Nome	Tipo
30	Diferença média com relação à cena(4)	Es	235	MCNC Homogeneidade 0°	Te
31	Diferença média com relação aos vizinhos (1)	Es	236	MCNC Homogeneidade 0° (1)	Te
32	Diferença média com relação aos vizinhos (2)	Es	237	MCNC Homogeneidade 0° (2)	Te
33	Diferença média com relação aos vizinhos (3)	Es	238	MCNC Homogeneidade 0° (3)	Te
34	Diferença média com relação aos vizinhos (4)	Es	239	MCNC Homogeneidade 0° (4)	Te
35	Valor mínimo dos pixels (1)	Es	240	MCNC Homogeneidade 135°	Te
36	Valor mínimo dos pixels (2)	Es	241	MCNC Homogeneidade 135° (1)	Te
37	Valor mínimo dos pixels (3)	Es	242	MCNC Homogeneidade 135° (2)	Te
38	Valor mínimo dos pixels (4)	Es	243	MCNC Homogeneidade 135° (3)	Te
39	Razão (1)	Es	244	MCNC Homogeneidade 135° (4)	Te
40	Razão (2)	Es	245	MCNC Homogeneidade 45°	Te
41	Razão (3)	Es	246	MCNC Homogeneidade 45° (1)	Te
42	Razão (4)	Es	247	MCNC Homogeneidade 45° (2)	Te
43	Razão com relação à cena (1)	Es	248	MCNC Homogeneidade 45° (3)	Te
44	Razão com relação à cena (2)	Es	249	MCNC Homogeneidade 45° (4)	Te
45	Razão com relação à cena (3)	Es	250	MCNC Homogeneidade 90°	Te
46	Razão com relação à cena (4)	Es	251	MCNC Homogeneidade 90° (1)	Te
47	Borda relativa aos vizinhos mais claros (1)	Es	252	MCNC Homogeneidade 90° (2)	Te
48	Borda relativa aos vizinhos mais claros (2)	Es	253	MCNC Homogeneidade 90° (3)	Te
49	Borda relativa aos vizinhos mais claros (3)	Es	254	MCNC Homogeneidade 90° (4)	Te
50	Borda relativa aos vizinhos mais claros (4)	Es	255	MCNC Homogeneidade todas as direções	Te
51	Desvio Padrão (1)	Es	256	MCNC Homogeneidade todas as direções (1)	Te
52	Desvio Padrão (2)	Es	257	MCNC Homogeneidade todas as direções (2)	Te
53	Desvio Padrão (3)	Es	258	MCNC Homogeneidade todas as direções (3)	Te
54	Desvio Padrão (4)	Es	259	MCNC Homogeneidade todas as direções (4)	Te
55	Desvio Padrão com relação aos pixels vizinhos (1)	Es	260	MCNC Média 0°	Te
56	Desvio Padrão com relação aos pixels vizinhos (2)	Es	261	MCNC Média 0° (1)	Te
57	Desvio Padrão com relação aos pixels vizinhos (3)	Es	262	MCNC Média 0° (2)	Te
58	Desvio Padrão com relação aos pixels vizinhos (4)	Es	263	MCNC Média 0° (3)	Te
59	Área (m²)	Fo	264	MCNC Média 0° (4)	Te

APÊNDICE 13. ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO E BANDAS DO SATÉLITE IKONOS-II QUE COMPÕEM O CONJUNTO INICIAL DE DADOS DE ENTRADA.

(continuação)

Nº	Bandas / atributos dos polígonos da segmentação		Nº	Bandas / atributos dos polígonos da segmentação	
	Nome	Tipo		Nome	Tipo
60	Área (excluídos os polígonos internos) (m <sup>2</sup> )	Fo	265	MCNC Média 135°	Te
61	Área (incluídos os polígonos internos) (m <sup>2</sup> )	Fo	266	MCNC Média 135° (1)	Te
62	Assimetria	Fo	267	MCNC Média 135° (2)	Te
63	Comprimento médio dos ramos (m)	Fo	268	MCNC Média 135° (3)	Te
64	Comprimento médio das bordas (m)	Fo	269	MCNC Média 135° (4)	Te
65	Comprimento médio dos ramos de ordem [1] (m)	Fo	270	MCNC Média 45°	Te
66	Área média representada pelos segmentos (m <sup>2</sup> )	Fo	271	MCNC Média 45° (1)	Te
67	Comprimento das bordas (m)	Fo	272	MCNC Média 45° (2)	Te
68	Compacidade (polígono)	Fo	273	MCNC Média 45° (3)	Te
69	Compacidade	Fo	274	MCNC Média 45° (4)	Te
70	Relação comprimento/curvatura (somente segmento principal)	Fo	275	MCNC Média 90°	Te
71	Grau de ramificação do esqueleto	Fo	276	MCNC Média 90° (1)	Te
72	Densidade	Fo	277	MCNC Média 90° (2)	Te
73	Distância à borda da imagem (m)	Fo	278	MCNC Média 90° (3)	Te
74	Distância à linha [1] (m)	Fo	279	MCNC Média 90° (4)	Te
75	Bordas maiores ddo que [1]	Fo	280	MCNC Média todas as direções	Te
76	Forma elíptica	Fo	281	MCNC Média todas as direções (1)	Te
77	Comprimento da borda mais longa (polígono) (m)	Fo	282	MCNC Média todas as direções (2)	Te
78	Comprimento do segmento principal (sem ciclos) (m)	Fo	283	MCNC Média todas as direções (3)	Te
79	Comprimento (m)	Fo	284	MCNC Média todas as direções (4)	Te
80	Comprimento do segmento principal (considerando ciclos) (m)	Fo	285	MCNC Desvio padrão 0°	Te
81	Relação comprimento/largura	Fo	286	MCNC Desvio padrão 0° (1)	Te
82	Relação comprimento/largura (somente segmento principal)	Fo	287	MCNC Desvio padrão 0° (2)	Te
83	Direção principal	Fo	288	MCNC Desvio padrão 0° (3)	Te
84	Comprimento da ramificação principal (m)	Fo	289	MCNC Desvio padrão 0° (4)	Te
85	Número de bordas (polígono)	Fo	290	MCNC Desvio padrão 135°	Te
86	Número de ramificações de comprimento [1]	Fo	291	MCNC Desvio padrão 135° (1)	Te
87	Número de ramificações de ordem [1]	Fo	292	MCNC Desvio padrão 135° (2)	Te
88	Número de objetos internos (polígono)	Fo	293	MCNC Desvio padrão 135° (3)	Te
89	Número de ângulos retos com bordas maiores do que [1]	Fo	294	MCNC Desvio padrão 135° (4)	Te
90	Número de segmentos	Fo	295	MCNC Desvio padrão 45°	Te

APÊNDICE 13. ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO E BANDAS DO SATÉLITE IKONOS-II QUE COMPÕEM O CONJUNTO INICIAL DE DADOS DE ENTRADA.

(continuação)

Nº	Bandas / atributos dos polígonos da segmentação		Nº	Bandas / atributos dos polígonos da segmentação	
	Nome	Tipo		Nome	Tipo
91	Número de segmentos de ordem [1]	Fo	296	MCNC Desvio padrão 45° (1)	Te
92	Perímetro (polígono) (m)	Fo	297	MCNC Desvio padrão 45° (2)	Te
93	Ajuste à forma retangular	Fo	298	MCNC Desvio padrão 45° (3)	Te
94	Índice de forma	Fo	299	MCNC Desvio padrão 45° (4)	Te
95	Desvio padrão da curvatura (somente segmento principal)	Fo	300	MCNC Desvio padrão 90°	Te
96	Desvio Padrão do comprimento das bordas (polígonos) (m)	Fo	301	MCNC Desvio padrão 90° (1)	Te
97	Desvio Padrão da área representada pelos segmentos (m <sup>2</sup> )	Fo	302	MCNC Desvio padrão 90° (2)	Te
98	Largura (m)	Fo	303	MCNC Desvio padrão 90° (3)	Te
99	Largura (somente segmento principal) (m)	Fo	304	MCNC Desvio padrão 90° (4)	Te
100	Coordenada X do centróide (m)	Fo	305	MCNC Desvio padrão todas as direções	Te
101	Coordenada X máxima (m)	Fo	306	MCNC Desvio padrão todas as direções (1)	Te
102	Coordenada X mínima (m)	Fo	307	MCNC Desvio padrão todas as direções (2)	Te
103	Distância X à borda esquerda da imagem (m)	Fo	308	MCNC Desvio padrão todas as direções (3)	Te
104	Distância X à borda direita da imagem (m)	Fo	309	MCNC Desvio padrão todas as direções (4)	Te
105	Coordenada Y do centróide (m)	Fo	310	VDNC 2º Momento Angular 0°	Te
106	Coordenada Y máxima (m)	Fo	311	VDNC 2º Momento Angular 0° (1)	Te
107	Coordenada Y mínima (m)	Fo	312	VDNC 2º Momento Angular 0° (2)	Te
108	Distância Y à borda superior da imagem (m)	Fo	313	VDNC 2º Momento Angular 0° (3)	Te
109	Distância Y à borda inferior da imagem (m)	Fo	314	VDNC 2º Momento Angular 0° (4)	Te
110	MCNC 2º Momento Angular 0°	Te	315	VDNC 2º Momento Angular 135°	Te
111	MCNC 2º Momento Angular 0° (1)	Te	316	VDNC 2º Momento Angular 135° (1)	Te
112	MCNC 2º Momento Angular 0° (2)	Te	317	VDNC 2º Momento Angular 135° (2)	Te
113	MCNC 2º Momento Angular 0° (3)	Te	318	VDNC 2º Momento Angular 135° (3)	Te
114	MCNC 2º Momento Angular 0° (4)	Te	319	VDNC 2º Momento Angular 135° (4)	Te
115	MCNC 2º Momento Angular 135°	Te	320	VDNC 2º Momento Angular 45°	Te
116	MCNC 2º Momento Angular 135° (1)	Te	321	VDNC 2º Momento Angular 45° (1)	Te
117	MCNC 2º Momento Angular 135° (2)	Te	322	VDNC 2º Momento Angular 45° (2)	Te
118	MCNC 2º Momento Angular 135° (3)	Te	323	VDNC 2º Momento Angular 45° (3)	Te
119	MCNC 2º Momento Angular 135° (4)	Te	324	VDNC 2º Momento Angular 45° (4)	Te
120	MCNC 2º Momento Angular 45°	Te	325	VDNC 2º Momento Angular 90°	Te

APÊNDICE 13. ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO E BANDAS DO SATÉLITE IKONOS-II QUE COMPÕEM O CONJUNTO INICIAL DE DADOS DE ENTRADA.

(continuação)

Nº	Bandas / atributos dos polígonos da segmentação		Nº	Bandas / atributos dos polígonos da segmentação	
	Nome	Tipo		Nome	Tipo
121	MCNC 2º Momento Angular 45º (1)	Te	326	VDNC 2º Momento Angular 90º (1)	Te
122	MCNC 2º Momento Angular 45º (2)	Te	327	VDNC 2º Momento Angular 90º (2)	Te
123	MCNC 2º Momento Angular 45º (3)	Te	328	VDNC 2º Momento Angular 90º (3)	Te
124	MCNC 2º Momento Angular 45º (4)	Te	329	VDNC 2º Momento Angular 90º (4)	Te
125	MCNC 2º Momento Angular 90º	Te	330	VDNC 2º Momento Angular todas as direções	Te
126	MCNC 2º Momento Angular 90º (1)	Te	331	VDNC 2º Momento Angular todas as direções (1)	Te
127	MCNC 2º Momento Angular 90º (2)	Te	332	VDNC 2º Momento Angular todas as direções (2)	Te
128	MCNC 2º Momento Angular 90º (3)	Te	333	VDNC 2º Momento Angular todas as direções (3)	Te
129	MCNC 2º Momento Angular 90º (4)	Te	334	VDNC 2º Momento Angular todas as direções (4)	Te
130	MCNC 2º Momento Angular todas as direções	Te	335	VDNC Contraste 0º	Te
131	MCNC 2º Momento Angular todas as direções (1)	Te	336	VDNC Contraste 0º (1)	Te
132	MCNC 2º Momento Angular todas as direções (2)	Te	337	VDNC Contraste 0º (2)	Te
133	MCNC 2º Momento Angular todas as direções (3)	Te	338	VDNC Contraste 0º (3)	Te
134	MCNC 2º Momento Angular todas as direções (4)	Te	339	VDNC Contraste 0º (4)	Te
135	MCNC Contraste 0º	Te	340	VDNC Contraste 135º	Te
136	MCNC Contraste 0º (1)	Te	341	VDNC Contraste 135º (1)	Te
137	MCNC Contraste 0º (2)	Te	342	VDNC Contraste 135º (2)	Te
138	MCNC Contraste 0º (3)	Te	343	VDNC Contraste 135º (3)	Te
139	MCNC Contraste 0º (4)	Te	344	VDNC Contraste 135º (4)	Te
140	MCNC Contraste 135º	Te	345	VDNC Contraste 45º	Te
141	MCNC Contraste 135º (1)	Te	346	VDNC Contraste 45º (1)	Te
142	MCNC Contraste 135º (2)	Te	347	VDNC Contraste 45º (2)	Te
143	MCNC Contraste 135º (3)	Te	348	VDNC Contraste 45º (3)	Te
144	MCNC Contraste 135º (4)	Te	349	VDNC Contraste 45º (4)	Te
145	MCNC Contraste 45º	Te	350	VDNC Contraste 90º	Te
146	MCNC Contraste 45º (1)	Te	351	VDNC Contraste 90º (1)	Te
147	MCNC Contraste 45º (2)	Te	352	VDNC Contraste 90º (2)	Te
148	MCNC Contraste 45º (3)	Te	353	VDNC Contraste 90º (3)	Te
149	MCNC Contraste 45º (4)	Te	354	VDNC Contraste 90º (4)	Te
150	MCNC Contraste 90º	Te	355	VDNC Contraste todas as direções	Te
151	MCNC Contraste 90º (1)	Te	356	VDNC Contraste todas as direções (1)	Te

APÊNDICE 13. ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO E BANDAS DO SATÉLITE IKONOS-II QUE COMPÕEM O CONJUNTO INICIAL DE DADOS DE ENTRADA.

(continuação)

Nº	Bandas / atributos dos polígonos da segmentação		Nº	Bandas / atributos dos polígonos da segmentação	
	Nome	Tipo		Nome	Tipo
152	MCNC Contraste 90° (2)	Te	357	VDNC Contraste todas as direções (2)	Te
153	MCNC Contraste 90° (3)	Te	358	VDNC Contraste todas as direções (3)	Te
154	MCNC Contraste 90° (4)	Te	359	VDNC Contraste todas as direções (4)	Te
155	MCNC Contraste todas as direções	Te	360	VDNC Entropia 0°	Te
156	MCNC Contraste todas as direções (1)	Te	361	VDNC Entropia 0° (1)	Te
157	MCNC Contraste todas as direções (2)	Te	362	VDNC Entropia 0° (2)	Te
158	MCNC Contraste todas as direções (3)	Te	363	VDNC Entropia 0° (3)	Te
159	MCNC Contraste todas as direções (4)	Te	364	VDNC Entropia 0° (4)	Te
160	MCNC Correlação 0°	Te	365	VDNC Entropia 135°	Te
161	MCNC Correlação 0° (1)	Te	366	VDNC Entropia 135° (1)	Te
162	MCNC Correlação 0° (2)	Te	367	VDNC Entropia 135° (2)	Te
163	MCNC Correlação 0° (3)	Te	368	VDNC Entropia 135° (3)	Te
164	MCNC Correlação 0° (4)	Te	369	VDNC Entropia 135° (4)	Te
165	MCNC Correlação 135°	Te	370	VDNC Entropia 45°	Te
166	MCNC Correlação 135° (1)	Te	371	VDNC Entropia 45° (1)	Te
167	MCNC Correlação 135° (2)	Te	372	VDNC Entropia 45° (2)	Te
168	MCNC Correlação 135° (3)	Te	373	VDNC Entropia 45° (3)	Te
169	MCNC Correlação 135° (4)	Te	374	VDNC Entropia 45° (4)	Te
170	MCNC Correlação 45°	Te	375	VDNC Entropia 90°	Te
171	MCNC Correlação 45° (1)	Te	376	VDNC Entropia 90° (1)	Te
172	MCNC Correlação 45° (2)	Te	377	VDNC Entropia 90° (2)	Te
173	MCNC Correlação 45° (3)	Te	378	VDNC Entropia 90° (3)	Te
174	MCNC Correlação 45° (4)	Te	379	VDNC Entropia 90° (4)	Te
175	MCNC Correlação 90°	Te	380	VDNC Entropia todas as direções	Te
176	MCNC Correlação 90° (1)	Te	381	VDNC Entropia todas as direções (1)	Te
177	MCNC Correlação 90° (2)	Te	382	VDNC Entropia todas as direções (2)	Te
178	MCNC Correlação 90° (3)	Te	383	VDNC Entropia todas as direções (3)	Te
179	MCNC Correlação 90° (4)	Te	384	VDNC Entropia todas as direções (4)	Te
180	MCNC Correlação todas as direções	Te	385	VDNC Média 0°	Te
181	MCNC Correlação todas as direções (1)	Te	386	VDNC Média 0° (1)	Te

APÊNDICE 13. ATRIBUTOS DOS POLÍGONOS DA SEGMENTAÇÃO E BANDAS DO SATÉLITE IKONOS-II QUE COMPÕEM O CONJUNTO INICIAL DE DADOS DE ENTRADA.

(conclusão)

Nº	Bandas / atributos dos polígonos da segmentação		Nº	Bandas / atributos dos polígonos da segmentação	
	Nome	Tipo		Nome	Tipo
182	MCNC Correlação todas as direções (2)	Te	387	VDNC Média 0° (2)	Te
183	MCNC Correlação todas as direções (3)	Te	388	VDNC Média 0° (3)	Te
184	MCNC Correlação todas as direções (4)	Te	389	VDNC Média 0° (4)	Te
185	MCNC Dissimilaridade 0°	Te	390	VDNC Média 135°	Te
186	MCNC Dissimilaridade 0° (1)	Te	391	VDNC Média 135° (1)	Te
187	MCNC Dissimilaridade 0° (2)	Te	392	VDNC Média 135° (2)	Te
188	MCNC Dissimilaridade 0° (3)	Te	393	VDNC Média 135° (3)	Te
189	MCNC Dissimilaridade 0° (4)	Te	394	VDNC Média 135° (4)	Te
190	MCNC Dissimilaridade 135°	Te	395	VDNC Média 45°	Te
191	MCNC Dissimilaridade 135° (1)	Te	396	VDNC Média 45° (1)	Te
192	MCNC Dissimilaridade 135° (2)	Te	397	VDNC Média 45° (2)	Te
193	MCNC Dissimilaridade 135° (3)	Te	398	VDNC Média 45° (3)	Te
194	MCNC Dissimilaridade 135° (4)	Te	399	VDNC Média 45° (4)	Te
195	MCNC Dissimilaridade 45°	Te	400	VDNC Média 90°	Te
196	MCNC Dissimilaridade 45° (1)	Te	401	VDNC Média 90° (1)	Te
197	MCNC Dissimilaridade 45° (2)	Te	402	VDNC Média 90° (2)	Te
198	MCNC Dissimilaridade 45° (3)	Te	403	VDNC Média 90° (3)	Te
199	MCNC Dissimilaridade 45° (4)	Te	404	VDNC Média 90° (4)	Te
200	MCNC Dissimilaridade 90°	Te	405	VDNC Média todas as direções	Te
201	MCNC Dissimilaridade 90° (1)	Te	406	VDNC Média todas as direções (1)	Te
202	MCNC Dissimilaridade 90° (2)	Te	407	VDNC Média todas as direções (2)	Te
203	MCNC Dissimilaridade 90° (3)	Te	408	VDNC Média todas as direções (3)	Te
204	MCNC Dissimilaridade 90° (4)	Te	409	VDNC Média todas as direções (4)	Te
205	MCNC Dissimilaridade todas as direções	Te			Te

Notas: \* Os códigos Ik, Es, Fo e Te referem-se a bandas do satélite Ikonos-II (Ik) e atributos espectrais (Es), de forma (Fo) e de textura (Te) dos polígonos da segmentação.

\*\* Os números entre parênteses que procedem aos nomes dos atributos referem-se à banda do satélite Ikonos-II utilizada para o cálculo deste atributo.